



**LISBOA
SCHOOL OF
ECONOMICS &
MANAGEMENT**

**MESTRADO EM
GESTÃO E ESTRATÉGIA INDUSTRIAL**

TRABALHO FINAL DE MESTRADO

TRABALHO DE PROJETO

ANÁLISE DO AJUSTAMENTO DA OFERTA À
PROCURA NA INDÚSTRIA DA PASTELARIA

HUGO JOSÉ SANTOS MARTINS

SETEMBRO - 2013



**LISBOA
SCHOOL OF
ECONOMICS &
MANAGEMENT**

MESTRADO EM GESTÃO E ESTRATÉGIA INDUSTRIAL

TRABALHO FINAL DE MESTRADO

TRABALHO DE PROJETO

**ANÁLISE DO AJUSTAMENTO DA OFERTA À
PROCURA NA INDÚSTRIA DA PASTELARIA**

HUGO JOSÉ SANTOS MARTINS

ORIENTAÇÃO:

PROFESSOR DOUTOR JOSÉ MIGUEL ARAGÃO CELESTINO SOARES

JÚRI:

PRESIDENTE:

PROFESSOR DOUTOR MANUEL DUARTE MENDES MONTEIRO LARANJA

VOGAL:

PROFESSOR DOUTOR PEDRO LUÍS PEREIRA VERGA MATOS

ABRIL - 2014

RESUMO

Este estudo pretende analisar a forma como o ajustamento da oferta à procura pode ser feito numa indústria tão imprevisível como é a da Pastelaria com o objetivo de reduzir o número de sobras sem agravar as ocorrências de *stockout*. No primeiro momento é realizado um estudo aprofundado da realidade bibliográfica que fundamenta todo o trabalho prático. Numa segunda fase, através da recolha de dados feita *a priori*, procede-se à elaboração do modelo de previsão e, para complementá-lo, é feito o estudo da realização do transporte que vai permitir o reajustamento da oferta. Posteriormente vai ocorrer a aplicação do modelo obtido como teste à sua eficiência prática na previsão da procura – tendo-se obtido um resultado positivo de €393,00 –, evidenciando as conclusões e recomendações para o futuro.

Palavras-chave: Pastelaria; Ajustamento da Oferta à Procura; Modelo de Previsão; Econometria; Transporte.

ABSTRACT

This research project aims to analyze how the adjustment of supply to demand can be done in an industry as unpredictable as the pastry with the goal of reducing the number of surplus without increasing occurrences of stockout.

At first, an in-depth study of the bibliographical reality that is fundamental for the practical work is conducted. In a second phase, through data collection *a priori* a statistical forecast model is constructed and, to complement it is studied the performance of transport which will allow the adjustment of the offer. Later will come the application of the model obtained as a test of its practical efficiency in forecasting demand – yielding a positive result of € 393.00 – highlighting the findings and recommendations for the future.

Keywords: Pastry; Adjusting of Supply to Demand; Forecasting Model; Econometrics; Transportation.

ÍNDICE

Resumo.....	i
Abstract	i
Lista de Figuras	iv
Lista de Tabelas.....	v
Índice dos Anexos	vi
Lista de Figuras dos Anexos	vii
Lista de Tabelas dos Anexos.....	viii
Glossário de Termos e Abreviaturas	ix
Agradecimentos.....	xi
1. Introdução e Objetivo	1
2. Revisão da Literatura	3
3. Metodologia	9
4. Apresentação e Análise de Dados	12
4.1. Caracterização da População e Amostra.....	12
4.2. Caracterização das Sobras.....	12
4.2.1. Stockout observado.....	14
4.3. Caracterização da Procura.....	15
4.3.1. Estatística descritiva.....	15
4.3.2. Inferência	16

5. Modelagem e Previsão	18
5.1. Construção do modelo	18
5.1.1. Modelo global vs. modelos individuais	18
5.1.2. Variáveis Explicativas	19
5.1.3. Testes ao Modelo	23
5.1.4. Reformulação do Modelo	24
5.1.5. Análise Retroativa ao Modelo de Previsão	25
5.2. Previsão One-Step-Ahead	27
5.2.1. Testes ao Modelo de Previsão	29
6. Transporte	30
6.1. Análise do melhor percurso.....	30
6.2. Considerações Finais sobre o Transporte.....	31
6.2.1. Horário de redistribuição	31
6.2.2. Análise das quantidades para redistribuição	32
7. Conclusões e Recomendações	33
Referências Bibliográficas	35
Anexos.....	37

LISTA DE FIGURAS

Figura 1 – Quantidade de Sobras de Cada Loja ao Longo dos Anos	13
Figura 2 – Percentagem das Sobras de Cada Loja ao Longo dos Anos	13
Figura 3 – Relação Entre as Sobras e as Vendas.....	14
Figura 4 – Contagem do <i>Stockout</i> Nos Anos 2010, 2011 e 2012.....	15
Figura 5 – Polígono da Frequência de Vendas por Loja em Classes de Amplitude 10	16
Figura 6 – Percentagem de Vendas de Cada Loja ao Longo dos Anos	17
Figura 7 – Percentagem de Vendas Diária de Cada Loja Com Regressão Linear	18
Figura 8 – Total Diário de Vendas Como Função do Dia-de-semana e Recodificação.....	19
Figura 9 – Média das Vendas ao Longo do Mês Com e Sem os Dias 24 e 31 de Dezembro ..	20
Figura 10 – Sobreposição Entre a Média Semanal de Vendas e o Padrão Mensal	21
Figura 11 – Comparação Entre as Médias de Vendas Mensais e as Médias Semanais	22
Figura 12 – Sobras Médias e <i>Stockout</i> Médio por Aplicação Retroativa do Modelo	26
Figura 13 – Comparação entre os valores observados e os valores ajustados com $IP_{55\%}$	27
Figura 14 – Melhor percurso passando pelas 5 lojas Trigo d’Aldeia (ciclo hamiltoniano)	30
Figura 15 – Percurso excluindo a Loja 5.....	31
Figura 16 – Custo do transporte vs. Lucro provisório de cada bolo	32

LISTA DE TABELAS

Tabela I – Caracterização Global das Vendas por Loja e por classes.....	16
Tabela II – Média e Intervalos de Confiança a 95% para a Percentagem de Vendas Diárias .	19
Tabela III – Desajustes entre o Padrão Mensal e as Vendas ao Longo das Semanas	21
Tabela IV – Estimação do Modelo com Estatística Robusta de White.....	24
Tabela V – Sobras Médias e <i>Stockout</i> Médio por Aplicação Retroativa do Modelo.....	25
Tabela VI – Previsão da Procura para o Mês de Julho com Base no Modelo Obtido	28
Tabela VII – IP55% e Comparação com as Vendas Registadas e os Valores Observados	29

ANEXOS

ÍNDICE

Anexos	vi
Lista de Figuras dos Anexos	vii
Lista de Tabelas dos Anexos	viii
Anexo A. (4.3 – Caracterização da Procura)	37
Anexo B. (4. 3 – Caracterização da Procura)	39
1. Testes Globais.....	39
2. Testes às Vendas por Loja	40
3. Testes às Percentagens Anuais de Vendas por Loja	41
Anexo C. (5.1 – Construção do Modelo).....	43
Anexo D. (5.1 – Construção do Modelo)	44
Anexo E. (6 – Transporte)	51

LISTA DE FIGURAS DOS ANEXOS

Figura 1 – Polígono da Frequência de Vendas por Loja	37
Figura 2 - Histograma e Caixa-de-bigodes das Vendas Globais	37
Figura 3 – Vendas por Loja ao Longo do Tempo.....	38
Figura 4 – N. Médio de Produtos Colocado à Venda por Loja ao Longo do Tempo.....	38
Figura 5 – Flutuação do Consumo ao Longo da Semana	39
Figura 6 – Médias de Vendas Globais por Loja e Possível <i>Clustering</i>	39
Figura 7 - Histograma das Quotas de Vendas e Caixas-de-bigodes.....	40
Figura 8 – Vendas Reais vs. Valor Esperado com Indício de Heterocedasticidade	50
Figura 9 – Mapa de Contexto Geográfico da empresa Trigo da Aldeia.....	51

LISTA DE TABELAS DOS ANEXOS

Tabela I - Caracterização das Vendas Globais	37
Tabela II - Caracterização Global das Vendas por Loja.....	38
Tabela III – Teste de Levene para a Homogeneidade de Variâncias das Vendas	39
Tabela IV – ANOVA para a Comparação das Médias de Vendas das Lojas.....	39
Tabela V - Caracterização das Quotas de Vendas e Testes de Normalidade	40
Tabela VI – ANOVAs Referentes à Vendas das Lojas ao Longo dos Anos.....	41
Tabela VII – Análise da Tendência	43
Tabela VIII – <i>Output</i> do modelo 1 – Sem tendência; com: sazonalidade, temperatura e precipitação como regressores.....	44
Tabela IX – <i>Output</i> do modelo 2 – Com: tendência, sazonalidade e temperatura como regressores	45
Tabela X – <i>Output</i> do modelo 3 – Com: tendência, sazonalidade, temperatura e a variável artificial <i>Chuva no verão</i> como regressores; AR(9)	46
Tabela XI – Coeficientes do modelo 3 – Com: tendência, sazonalidade, temperatura e a variável artificial <i>Chuva no verão</i> como regressores; AR(9)	47
Tabela XII – Modelo 4 – Com: tendência, sazonalidade, temperatura e a variável artificial <i>Chuva no verão</i> como regressores; AR(2).....	48
Tabela XIII – Modelo 4 – Com: tendência, sazonalidade e a variável artificial <i>Chuva no verão</i> como regressores; AR(2).....	49
Tabela XIV – Teste de White Special	50
Tabela XV – Modelo com erros heterocedástico-consistentes de White	51

GLOSSÁRIO DE TERMOS E ABREVIATURAS

Algoritmo	Processo de resolução passo-a-passo baseado num conjunto de regras para se obter a solução (ou critério de paragem) de um cálculo ou de um processamento de dados.
ANOVA	<i>Analysis of variance</i> , i.e., trata-se de uma análise da variância que verifica se existe uma diferença significativa entre as médias de uma variável dependente particionada em diversas amostras, ou seja, se os fatores independentes exercem influência sobre a variação da variável dependente. Deste modo a ANOVA generaliza o teste t que compara apenas a média entre duas amostras.
<i>ceteris paribus</i>	Expressão em latim que significa ‘com tudo o resto constante’. Forma de simplificar a análise de um modelo no qual se pretende avaliar o impacto de uma certa variável assumindo que as restantes não se alteram.
Ciclo hamiltoniano	Caminho fechado (i.e. o ponto de partida e chegada coincidem) no qual todos os vértices são percorridos uma e uma só vez.
Espúrio	Uma relação entre duas variáveis diz-se espúria quando não existe uma ligação causal entre elas mas, no modelo considerado, surge uma correlação estatisticamente significativa (ou por coincidência ou devido a um outro fator oculto).
$\left\{ \begin{array}{l} H_0 \\ H_1 \end{array} \right.$	Hipótese nula contra hipótese alternativa. Um teste de hipóteses estatístico tem H_0 e H_1 como partição do espaço de resultados, ou seja são complementares. H_0 recebe o “benefício da dúvida” de modo que só é rejeitada quando há evidência estatística para esse efeito.
Heurística	Técnica de resolução de problemas baseada em regras empíricas. Aplica-se quando nem a solução analítica é possível de ser determinada nem o levantamento exaustivo de todas as hipóteses é praticável. Deste modo, não garante que a solução encontrada é ótima.
Homocedasticidade / Heterocedasticidade	Heterocedasticidade é a designação do fenómeno estatístico que ocorre quando as variâncias das observações das variáveis explicativas não são estatisticamente iguais. Afeta sobretudo a eficiência dos estimadores. Homocedasticidade designa a igualdade de variâncias.
Kurtosis (ou curtose)	É uma medida do pico ou achatamento da curva de distribuição de uma variável. Serve sobretudo para comparação com a distribuição normal cuja <i>kurtosis</i> tem o valor nulo. Valores positivos representam uma distribuição cujo pico é superior e a largura inferior à normal.

NP complexo	Classe de problemas cuja complexidade é polinomialmente não determinística. Por exemplo, problemas cujo número de cálculos cresce exponencialmente com o número de fatores.
<i>Outliers</i>	Observação quantitativamente distante das outras. Na estatística descritiva os <i>outliers</i> podem ser superiores ou inferiores, moderados ou severos. Se o afastamento entre a observação o 3º quartil é superior a uma vez e meia da amplitude inter-quartil mas inferior ao seu triplo, o <i>outlier</i> diz-se superior e moderado; se esse afastamento é superior ao triplo da amplitude inter-quartil, o <i>outlier</i> é superior e severo.
TLC	Teorema do Limite Central, também denominado Lindeberg–Lévy. Dadas certas condições gerais de amostragem, a média das variáveis independentes e identicamente distribuídas converge para uma distribuição normal.
valor-p	É uma medida de significância dada pela probabilidade de se obter o valor observado numa dada amostra ou outros mais desfavoráveis para H_0 , assumindo H_0 verdade. Na prática, um valor diminuto do valor-p (< 5%) leva à rejeição de H_0 .
Variável artificial (ou <i>dummy</i>)	Também designada por variável binária, booleana, lógica, categorizante ou qualitativa. Esta variável assume o valor ‘1’ quando uma certa característica se verifica e ‘0’ caso contrário. A utilização de várias variáveis artificiais mutuamente exclusivas permite particionar o espaço de resultados.
Tipo normativo	É um modelo da teoria da decisão que indica qual deve ser o comportamento dos decisores racionais ou coerentes.
CrITÉrio de Bayes	Trata-se de um critério quantitativo para a tomada de decisão no qual se deve incorporar toda a informação no problema traduzindo-se a mesma pela atribuição de ponderações, probabilidades subjectivas ou graus de credibilidade aos diferentes estados.
AR(n)	Modelo autoregressivo de ordem n.
IP	Intervalo de Previsão
SDL	<i>Substitute, Delay or Leave</i> . É a resposta tripartida de um potencial cliente perante uma situação de <i>stockout</i> do produto num determinado ponto de vendas.

AGRADECIMENTOS

No momento de agradecer quero prestigiar todos aqueles que caminharam comigo ao longo destes anos, pois contribuíram para que fosse possível realizar, mais do que um objetivo de vida, um sonho.

Ao ISEG. Para mim é um orgulho fazer parte da história de uma Instituição tão prestigiada e que me deu tanto a vários níveis. Agradeço muito aos professores que me ajudaram a ser melhor, quer como pessoa, quer em termos académicos. Não posso deixar de agradecer aos funcionários do ISEG, alguns deles verdadeiros amigos.

Ao Professor Doutor José Miguel Soares pela competência e entrega que deu ao trabalho. A sua disponibilidade e a forma com que se relaciona informalmente com os alunos é um exemplo a seguir.

Um agradecimento muito emotivo aos meus amigos Jorge Gouveia e Nuno Cruz. Juntos temos percorrido um caminho até aqui que eu nunca vou esquecer. Eu agradeço-vos muito, campeões.

À minha namorada pela importância que tem na minha vida.

O agradecimento especial para a minha família, a força da minha vida está em vocês. Sinto-me privilegiado por ser um de vós. Amo-vos.

1. INTRODUÇÃO E OBJETIVO

Este trabalho de projeto tem como objetivo central estudar a forma como as sobras de bolos podem ser minimizadas na empresa Trigo da Aldeia, Lda. que está implementada no mercado da pastelaria desde junho de 1999, e que produz os artigos de pastelaria variada que são comercializados nas suas cinco lojas, todas localizadas no concelho de Sintra.

Como se trata de um tipo de negócio em que não é possível saber com exatidão o valor da procura, os desajustamentos entre esta e a oferta têm uma elevada tendência para acontecer diariamente ou porque há um excedente de produto (criando assim uma percentagem que não é vendida) ou então, por vezes, pode acontecer o contrário – a quantidade de bolos produzida ser insuficiente (originando *stockout*). Quando esta última situação ocorre significa que a procura é superior à oferta, i.e., quando os clientes se dirigem à loja já não há produto para vender – o que pode não ser necessariamente contraproducente, caso aconteça perto da hora de encerramento do ponto de venda. O impacto do *stockout* perante o consumidor pode ser negativo, gerar a expectativa do mesmo e criar a imagem de falta de oferta. Mas por outro lado deve existir um equilíbrio entre estas eventuais situações e um excesso de desperdício, até porque se trata de um artigo cujas vendas pouco se realizam junto do fim do expediente.

O tipo de bolos alvo do estudo é a pastelaria variada, pois estes são de consumo corrente e de venda variável como por exemplo bolas de Berlim, pastéis de nata, etc. O pão que sobra é reaproveitado enquanto que o outro género de bolos, os entremeios, de maior dimensão – como é o caso dos bolos de aniversário – são fabricados sob encomenda ou para promover o produto junto dos consumidores, pelo que o trabalho não incide sobre tais produtos.

Atualmente a empresa faz as suas previsões de forma empírica, em que estas são realizadas com critérios intuitivos. O que acontece na prática é que a previsão é realizada diariamente pelos pasteleiros que se baseiam nas informações disponibilizadas pelas responsáveis de cada loja, aumentando ou diminuindo a quantidade fabricada de bolos dependendo dos dados

obtidos e da experiência acumulada ao longo dos anos. Isto faz com que haja uma maior necessidade de dar um salto qualitativo na gestão das empresas, nomeadamente na redução de desperdícios e na procura de obtenção de ganhos na gestão do produto, justificando assim a introdução de um modelo de previsão elaborado pelo gestor, pois é necessário dar resposta às exigências dos novos tempos.

Segundo Caiado (2011), o gestor que se recusa a fazer uma previsão da procura, está por omissão, a tomar decisões baseadas no vazio ou na manutenção das condições presentes. Contextualizando no cenário económico que hoje se vive e também com o aumento da carga fiscal que se tem vindo a verificar no setor conclui-se que é precisa uma gestão mais profissionalizada que traga um valor acrescentado na área da previsão.

Para complementar a previsão da procura, procede-se ao estudo da tomada de decisão da realização do transporte, o qual vai permitir um reajustamento por dia, à medida das vendas efectuadas e no período mais adequado – à tarde –, pois nesta fase é possível ter uma percepção mais concreta do que pode acontecer até à hora de encerramento das lojas.

Este estudo está dividido em 7 capítulos, em que depois da análise introdutória e definido o objetivo principal, no capítulo 2 é feita a revisão da literatura mais importante e que mais se ajusta ao tema. No terceiro momento é explanada a metodologia utilizada que vai permitir desenvolver o modelo previsional e tecer considerações sobre o transporte do produto.

Na quarta fase é elaborada a apresentação e análise dos dados recolhidos ao longo dos três anos e meio, e o capítulo 5 contém toda a construção do modelo e a previsão que ele permite obter. A fase seguinte diz respeito à decisão da utilização do transporte e a sua complementaridade à previsão realizada. No último capítulo é feita a reflexão de todo trabalho com as respetivas conclusões e recomendações para o futuro.

2. REVISÃO DA LITERATURA

A importância do estudo da previsão da procura prende-se, naturalmente, com a gestão do inventário e do produto no sentido de melhor corrigir o desajustamento entre aquela e a oferta. A previsão é um ato intrínseco à gestão e à tomada de decisão estratégica (Caiado, 2011, p. 9) e, no tipo normativo, deve-se tentar prever as consequências de uma sequência de decisões (Murteira, 1996, pp. 14, 15).

O objetivo da gestão estratégica é a eficiência e o lucro da empresa (Hill & Jones, 2008). No contexto das lojas Trigo da Aldeia o lucro da empresa passa por se ter um ajustamento da oferta à procura de modo a que não haja nem sobras, nem faltas de bolos – meta esta que é utópica dada a aleatoriedade inerente a este tipo de negócio. Perante isto, deve a gestão decidir acerca da produção diária, incorporando toda a informação neste processo: adotando a previsão como referência e ponderando as consequências do desajuste, i.e., um número excessivo de sobras por um lado, até à falta de produto no outro extremo (Murteira, 1996, pp. 19, 40, 41).

Como refere Gilliland (2003) a ação de prever (nomeadamente prever a procura) é difícil e ingrata não só porque a precisão não atinge os valores desejados, mas também muitos gestores usam a previsão como uma forma de pressionar o departamento de vendas de modo a atingir os objetivos certos objetivos de vendas – deste modo surge a tendência para sobrestimar o que, no contexto deste projeto, significa o surgimento de sobras. O mesmo autor, e Moon, Mentzer, Smith e Garver (1998), defendem que a previsão deve partir de uma análise o mais fidedigna e imparcial possível e, sobre esta, é que devem atuar outros fatores tais como a referida necessidade de estabelecer um objetivo de vendas, *marketing*, etc., mesmo que o nível alcançável de precisão seja substancialmente inferior ao que se deseja.

A excelência da gestão passa pela melhor previsão possível e pelo transporte do produto por forma a impedir que as faltas da oferta levem a que os consumidores se afastem e a menores níveis de fidelização.

O princípio básico da análise da decisão não é de todo substituir a intuição do decisor, aliviá-lo(a) das incumbências de lidar com o problema, nem, pior ainda, competir contra o estilo pessoal de análise do decisor – mas sim complementar, aumentar e cooperar no geral com o decisor exemplificando a natureza do problema. Em última análise, é da maior importância que o decisor aprenda algo sobre o problema e sobre a sua atitude ao decidir (Bunn, 1984).

Ao aceitar-se esta definição deve a gestão procurar conhecer os fatores decisivos que assentaram com base na intuição dos decisores e, tanto quanto possível, deve procurar atribuir-lhes uma “quantificação ou ponderação” (Murteira, 1996, p. 41). Assim sendo, para além da pesquisa bibliográfica usual, neste estudo procurou-se fazer um levantamento de dados junto de entidades da indústria (AIPL-Associação dos Industriais da Panificação de Lisboa; AIPAN-Associação dos Industriais da Panificação, Pastelarias e Similares do Norte e ACIP-Associação do Comércio e da Indústria de Panificação, Pastelaria e Similares).

Por outro lado, este processo faz-se envolvendo vários setores da empresa: o registo de vendas; a gestão; a confeção e o transporte. É neste dinamismo que a excelência da previsão de vendas pode elevar a moral financeira de uma empresa e ser gratificante tanto para os clientes como para os funcionários (Moon, Mentzer, Smith, & Garver, 1998). Trata-se também de construir uma ponte entre a gestão superior e a chefia intermédia – o que promove a saúde do ambiente empresarial.

Em última análise realizar a previsão é nada mais nada menos que a aplicação sistemática e disciplinada do senso comum (Saffo, 2007).

Um olhar crítico sobre a previsão deve assentar na lógica e bom senso avaliando-se as oportunidades e riscos. Naturalmente que a construção de uma previsão assertiva passa pela consciência de que uma redução da produção reduz a quantidade de sobras mas aumenta as ocorrências de *stockout* – pelo que esta situação não pode ser negligenciada neste estudo.

Avaliar o impacto do *stockout* é algo difícil, pois não só é impossível prever qual o verdadeiro valor da procura, como é igualmente custoso avaliar as repercussões que causa no consumidor. Sendo possível estimar as consequências tangíveis diretas, o mesmo já não acontece com os efeitos intangíveis, que vão desde a perda de clientes (no caso de *stockouts* sucessivos) como o passa-palavra negativo, sendo este fundamental no comércio tradicional e geograficamente instalado (Anderson, 1998). O impacto no objeto de estudo é relevante pois não só o comércio da panificação / pastelaria é maioritariamente realizado “à porta de casa”, ou junto de escolas/locais de trabalho, mas também acresce o facto de as 5 lojas da empresa Trigo da Aldeia se encontrarem geograficamente próximas.

A facilidade da comunicação que as novas tecnologias promovem permite que não só o consumidor tenha acesso à informação, como tenha igualmente acesso a publicar a sua opinião, e a divulgar a informação que ache pertinente. Neste campo, Zhu & Zhang (2010) destacam o impacto que o *feedback* dos consumidores recai sobretudo sobre as empresas da área das tecnologias de informação, e nas que apostam num grande *marketing online*. Contudo, os efeitos no comércio retalhista tradicional têm vindo a aumentar dado a alteração do paradigma comunicacional. Salientando esta realidade Mangold e Faulds (2009) alertam para um sistema híbrido de comunicação empresa-consumidor, desde os meios promocionais usuais até à interação via redes sociais virtuais, que é igualmente uma forma de relação consumidor-consumidor. Seria exagerado pensar-se que, por não encontrar o bolo pretendido, o consumidor iria imediatamente deixar uma mensagem negativa no *Facebook* do Trigo da Aldeia, mas, em caso de repetição, tal pode acontecer, uma vez que a rede social é a extensão

natural do passa-palavra (Mangold & Faulds, 2009) e esta exponencia o público-alvo em várias ordens de grandeza (Gillin, 2007).

A empresa deve estar consciente desta realidade e abraçá-la na sua estratégia de *marketing* evitando os *feedbacks* negativos que poderiam ter origem no mau atendimento, na falta de qualidade dos produtos e na ausência destes para venda – pois é mais fácil publicar uma reclamação no meio virtual do que deixar um comentário positivo (Dimensional Research - ZenDesk, 2013).

Perante uma situação de *stockout*, Zinn e Liu (2001) referem 3 respostas possíveis por parte dos consumidores, que referem com o acrónimo SDL¹:

1. Substituição do artigo por outro – situação esta que não se aplica no contexto deste trabalho de projeto;
2. Adiar a compra do mesmo – sendo que entra como consumo para a estatística referente ao dia seguinte;
3. Sair do ponto de venda não realizando consumo algum nesta loja, porque ou se desiste, ou se vai procurar o mesmo produto numa loja concorrente.

A terceira situação, dado o tipo de produto de que se trata e a hora tardia a que eventualmente ocorre o *stockout*, faz com que os consumidores assumam um certo constrangimento demográfico e, neste caso, limitem a procura de uma loja concorrente na vizinhança mais próxima, sendo que a maioria simplesmente desiste da compra. Com o intuito de incorporar a situação referida pelos autores no número 2, procurou-se averiguar se existia algum tipo de pico de vendas nos dias seguintes ao *stockout*. Tal conclusão não é estatisticamente viável nos valores observados sendo que os próprios picos de vendas é que coincidem com o *stockout* – cf. secção 4.2.1.

¹ SDL: *Substitute, Delay, Leave*, no texto original – Cf. Glossário, pág. vi.

A eficiência e utilidade prática do modelo de previsão passa pelo reconhecimento da incerteza e aleatoriedade inerente ao fenómeno da procura, de modo a que o gestor consciente possa tomar a decisão de compromisso mais correta. Por este mesmo motivo deve associar-se uma margem de erro útil à previsão, e procurar mecanismos que permitam minorar o impacto dos desajustes nomeadamente através de um horário flexível para a redistribuição do produto (Fisher, Hammond, Obermeyer, & Raman, 1994) – questão esta que se aborda complementarmente à previsão no Capítulo 6 – Transporte. Estes mesmos autores reforçam a ideia da gestão tomar consciência dos erros de previsão – algo que tipicamente havia sido negligenciado pelas empresas. Outro fator presente é o crescimento do volume de vendas ao qual está associado uma maior imprevisibilidade. Esta questão força as empresas a alterar o modo de prever a procura e a logística da distribuição, pois as antigas formas de antecipar as vendas não mais se aplicam com o desejado nível de rigor. Sem fugir a este enquadramento, a expansão do Trigo da Aldeia levou a que a previsão intuitiva tenha dado origem a cada vez maiores níveis de sobras.

Uma prática evidente para a análise crítica da previsão é a compará-la regularmente com os valores observados, e manter a capacidade de reformular o modelo sempre que tal se justifique. Saffo (2007) e Fisher *et al.* (1994), afirmam a necessidade do gestor continuamente reformular os paradigmas sobre os quais assentam a previsão, pois o que são hoje variáveis explicativas podem, num futuro recente, tornar-se irrelevantes. A previsão não é uma mera fórmula, mas uma ferramenta dinâmica que necessita de ser avaliada e redefinida. Momentos de grande imprevisibilidade são também momentos chave nos quais emergem oportunidades e fatores relevantes.

As ferramentas estatísticas existem para que o gestor consiga distinguir quais as variáveis que adquirem capacidade explicativa numa área tão imprevisível como o consumo.

Se por um lado, ao lidar-se com bens alimentares se espera um mercado menos volátil que o das novas tecnologias, por outro lado, a rápida forma como o paradigma da comunicação tem unido os consumidores, e o impacto que as tendências alimentares – mais ou menos fortuitas – têm na formação da opinião pública, acrescem rápidas variações ao consumo.

A gestão necessita de estar atenta e procurar não só seguir tendências no campo alimentar, como adotar uma postura pró-ativa e colocar-se na vanguarda da mudança; caso contrário só consegue realizar previsões de factos já ocorridos. Estar preparado para reformular modelos, investigar variáveis e alterações a hábitos enraizados de consumo faz parte das competências de um gestor que deseja ter a sua empresa competitiva. Não só se pretende evitar o desperdício e o *stockout* de artigos de pastelaria tradicional, como também sondar as tendências para a apresentação de novos produtos que colmatem a oferta existente, e venham ao encontro das expectativas e desejos do consumidor, tantas vezes influenciados por campanhas e modas – e.g. prevenção da diabetes e da obesidade infantil; tendência *gourmet*, etc.

A previsão da procura deve ser enquadrada num contexto vasto, tanto para a decisão da quantidade a produzir, como para avaliar tendências emergentes. Prever uma diminuição no consumo é antever o surgimento de um novo produto (Saffo, 2007).

Em última análise, o papel do gestor é de compreender o meio à sua volta, tanto industrial como humano, e aplicar o senso comum mantendo um olhar crítico sobre os padrões existentes ao mesmo tempo que procura tendências emergentes. O gestor que se recusa assumir este papel adota uma postura passiva limitando a sua ação a uma atividade algorítmica e negando a sua própria consciência (ver, por exemplo, Penrose (1997)).

“A melhor forma de compreender o futuro é realizar a previsão por si mesmo” (Saffo, 2007)

3. METODOLOGIA

Os dados utilizados neste trabalho foram obtidos nos últimos três anos e meio, desde o início de 2010 a junho de 2013. Durante este período a responsável de cada uma das cinco lojas fez a contabilização diária das quantidades vendidas e o respetivo registo com as quantidades de produto não vendido, chegando mesmo, nalguns dias, a atingir um valor considerável significando que o planeamento necessita de um modelo que ajude a prever as necessidades. Estes dados foram cruzados com a informação relativa às quantidades produzidas fornecida pelo pasteleiro responsável. É também ele que decide quais as porções a transportar para cada uma das 5 lojas.

A informação que diz respeito às variáveis temperatura média e precipitação média diárias para o concelho de Sintra foi recolhida junto do Instituto Português do Mar e da Atmosfera. A temperatura média do ar foi medida na estação meteorológica Sintra/Pena, enquanto que para a precipitação procedeu-se à média entre o valor da estação meteorológica situada em Cabo Raso e a estação situada em Lisboa para o mesmo período de tempo.

Para a tomada de decisão do transporte o estudo serve-se do Google Maps[®] para saber de forma exata a distância entre as 5 lojas, sendo esta confirmada pela viatura da empresa. A medição do tempo médio para percorrer todos os pontos de venda, foi encontrado através da realização do percurso durante duas semanas e em vários períodos do dia.

A investigação que o trabalho exige em termos de recolha de dados da Indústria da pastelaria em Portugal demonstra que existe muito por fazer nesta área de negócio em termos de estudos, isto porque a procura de informação quer junto das associações do setor quer junto das instituições académicas evidencia um vazio que deve ser preenchido.

Nesta indústria verifica-se que a procura relativa aos diferentes produtos é altamente correlacionada – por exemplo, um cliente que se dirija a uma loja com o objetivo principal de

aquisição de pão acaba por levar um ou mais bolos, e vice-versa. Neste contexto, o método recomendado é o da análise multivariada (Stefanescu, 2009). Sendo o objetivo principal evitar o desperdício – o que não acontece com o pão – optou-se pelo estudo exclusivo do produto bolos num contexto de série temporal. A questão do ajustamento dos modelos de regressão aplicados a estas séries é fulcral para a construção do modelo de previsão e o considerável volume de dados permite realizar uma inferência assintoticamente válida.

Nos 3 anos e meio a que se refere o estudo a situação de esgotamento do produto ocorreu em 88 ocasiões (menos de 7%) pelo que pode considerar-se que o valor das vendas desses dias constitui uma estimativa da procura (Stefanescu, 2009) sem necessidade de outros ajustamentos que teriam como consequência o enviesamento dos estimadores.

Uma etapa fundamental deste trabalho é a construção de um modelo de previsão adequado. A previsão deve procurar antecipar os efeitos que até mesmo correntes ocultas podem gerar (Saffo, 2007) pelo que se justifica um levantamento das diversas variáveis que podem influenciar o consumo na área da pastelaria. O mesmo autor argumenta que é preferível alargar o “cone de incerteza” por forma a incorporar fatores aparentemente desgarrados do que estreitá-lo uma vez que as ferramentas estatísticas permitem refinar o modelo posteriormente. Deste modo, identificou-se as seguintes variáveis explicativas para o modelo:

- Decomposição cronológica dos movimentos de tendência e sazonalidade;
- Reconhecimento da terceira componente característica que é outros movimentos oscilatórios da realidade económica cujos ciclos longos e de periodicidade indefinida dificilmente são separáveis da tendência (Murteira, Müller, & Turkman, *Análise de Sucessões Cronológicas*, 1993, p. 6), pelo que não foi explicitamente incluída;
- Na investigação do quarto fator, muito característico das séries temporais, que é o da autocorrelação, o que vai ao encontro da tomada de decisão intuitiva que se baseia na quantidade vendida no dia anterior.

O modelo procura realizar a melhor previsão mantendo-se inteligível por quem o usa, i.e., deve-se evitar a inclusão de um número excessivo de variáveis cujo papel a desempenhar se torne pouco claro, o que levaria a negligenciar o recurso à previsão (Moon, Mentzer, Smith, & Garver, 1998). O modelo deve igualmente ser construído assentando na lógica clara de forma que o gestor, ao recorrer a esta ferramenta, consiga explicar as razões sobre as quais assenta a sua decisão (Saffo, 2007). Por este motivo procurou-se agrupar a sazonalidade, i.e. os dias de produção, em semanas e meses cuja lógica seja defensável pelo gestor tendo como base de comparação as análises estatísticas menos intuitivas tais como a redução de fatores e extração de componentes principais – sendo de destacar o elevado grau de concordância.

Fazendo bem a distinção entre a “precisão” e a “utilidade” de uma previsão, Saffo (2007) argumenta que a incerteza da previsão é parte integrante da mesma e que a utilidade desta assenta na definição de um “cone de incerteza” que seja razoável de forma a encontrar-se um compromisso entre a capacidade de previsão, o erro aceitável e a complexidade do modelo no sentido de este ser útil e aplicável como auxiliar do planeamento estratégico. A previsão desempenha um papel fundamental no processo de planeamento, tomada de decisão e controlo em qualquer organização, conforme afirma Caiado (2011). Por este motivo o modelo de previsão ajustado será testado teoricamente em relação aos valores retroativos e, sobretudo, será aplicado na prática em relação aos valores de julho de 2013, com o objetivo de se efetuar o melhor planeamento possível da produção.

A análise estatística é aqui efetuada recorrendo-se ao *software* usual, nomeadamente Microsoft® Excel® e, sobretudo, IBM® SPSS®.

Baseada na revisão da literatura apresentada no capítulo anterior e na metodologia atrás citada, apresentamos agora a pergunta central de investigação:

- Qual o modelo de previsão que melhor consegue estimar as vendas e permite corrigir o desajustamento entre a oferta e a procura na indústria de pastelaria?

4. APRESENTAÇÃO E ANÁLISE DE DADOS

4.1. *Caracterização da População e Amostra*


Esta caracterização permite enquadrar o universo e objeto de estudo, partindo de uma análise exploratória para a inferência indutiva (Murteira, Ribeiro, Silva, A., & Pimenta, 2010, p. 2) – na qual se pretende cumprir com o objetivo de previsão da procura para ajustar a produção em conformidade. A população consiste na empresa Trigo d’Aldeia cujas unidades estatísticas são as 5 lojas que a constituem, estando estas localizadas no Cacém e Massamá, concelho de Sintra. Os dados recolhidos pertencem à categoria de dados temporais, de frequência diária, inseridos numa amostra recolhida desde o dia 1 de janeiro de 2010 até 30 de junho de 2013 inclusive. As variáveis observadas, de natureza quantitativa, são: produção diária de bolos e número de bolos que ficaram por vender no final do dia – i.e. sobras. A quantidade produzida é bem controlada e a contagem de sobras é realizada diariamente. Os erros associados são desprezáveis devido ao controle da contagem e às quantidades diminutas – não se enquadrando nos usuais processos estocásticos modelados por uma distribuição de Poisson (Murteira, Ribeiro, Silva, A., & Pimenta, 2010, p. 184). O processo de amostragem permite a classificação de amostra casual, estocástica, embora, e como é típico de séries temporais, não exista independência ao longo do tempo (Wooldridge, 2009, p. 348).

A população interseta o universo dos consumidores maioritariamente de Sintra, cuja amostra se caracteriza por uma maior percentagem feminina e por pessoas correspondentes à faixa etária reformada – o que confere com o contexto sociocultural português.

4.2. *Caracterização das Sobras*

Optou-se por descrever primeiramente a variável “sobras” (Figura 1) pois esta demonstra diretamente o problema que se pretende minorar. Por outro lado, como não é o objeto imediato da previsão, a sua inferência é menos exaustiva e serve para introdução à problemática da dualidade oferta-procura. No geral, a média é de 27,04 por dia e por loja.

Figura 1 – Quantidade de Sobras de Cada Loja ao Longo dos Anos


**Nota:**

a barra correspondente a 2013 contém apenas os dados até 30 de junho pelo que não é comparável com as anteriores. A sua inclusão serve como registo das quantidades.

Fonte: Elaboração própria

Este gráfico da Figura 1 demonstra uma ligeira tendência para o crescimento das sobras mantendo-se quasi-constante a proporção entre as lojas – como se verifica na Figura 2 e nos reduzidos valores dos declives das retas de regressão que a mesma apresenta.


Figura 2 – Percentagem das Sobras de Cada Loja ao Longo dos Anos



Fonte: Elaboração própria

Esta situação demonstra que, para abastecer uma loja que vende mais, superior é também a margem de erro atribuída aquando do fabrico do produto pelo que, em média, as sobras são em maior quantidade. Estes fatores agravam a heterocedasticidade já inerente à procura. O elevado grau de correlação de 0,866 entre as sobras e as vendas corrobora esta hipótese e constata-se que uma maior quantidade de sobras tem igualmente uma variabilidade superior.

Figura 3 – Relação Entre as Sobras e as Vendas



Fonte: Elaboração própria


4.2.1. Stockout observado

As situações de *stockout*, i.e., de escoamento total de produto num certo ponto de venda, é definido através da nulidade das sobras. Como não é possível saber quantos bolos ficaram por vender, a variável é definida de forma binária. Em 1270 dias de produção observados, esta situação ocorreu 88 vezes (6,93%). Um exame atento (Figura 4) remete para 3 características:

- A frequência com que ocorre o *stockout* é reduzida;
- A grande tendência é para um excesso de produção – i.e., elevadas sobras;
- A decisão da quantidade de produção assenta sobretudo na experiência e na intuição e nas sobras do dia anterior.

Perante esta qualificação do contexto em que a produção é realizada é lícito assumir-se que o *stockout* sucede em situações atípicas e nas quais a intuição falha – pelo que este estudo pode revelar fatores úteis para o modelo de previsão.

No gráfico seguinte (Figura 4) optou-se por não considerar o *stockout* de 2013, visto que o ano não está completo e iria gerar um desequilíbrio. Deste modo fez-se a contagem das ocorrências (processo binomial) nos restantes anos.

Figura 4 – Contagem do *Stockout* Nos Anos 2010, 2011 e 2012

Fonte: Elaboração própria


A sobreposição do gráfico de *stockout* com as vendas mostra que a ocorrência deste último corresponde numerosas vezes a picos de vendas – situação esta que era expetável. Para além das coincidências de *stockout* no mesmo dia do ano destaca-se a densidade deste fenómeno no verão, o que demonstra que, nestes meses de baixo consumo, a margem de erro atribuída à produção é igualmente menor e certas oscilações na procura causam o *stockout* com mais facilidade. Verificando-se os dados meteorológicos, a situação de chuva no verão aconteceu 17 vezes desde 2010 a 2012, das quais 12 coincidem com o *stockout*, ou seja, 70,59%. Este dado é relevante na compreensão do consumo e será considerado no modelo de previsão.

4.3. Caracterização da Procura

4.3.1. Estatística descritiva

A análise das vendas revela um reflexo direto da procura que se pretende prever. Deste modo, torna-se fundamental conhecer e caracterizar a amostra com o objetivo primário de escolher os modelos de previsão mais adequados. A análise exploratória será ilustrada pelas figuras adequadas; contudo, e para efeito de clareza, os dados serão agrupados e classificados em classes de amplitude uniforme (Murteira, Ribeiro, Silva, A., & Pimenta, 2010, p. 15). A análise dos dados não classificados e respetivos gráficos é apresentada no Anexo A. Como se verifica na Figura 5 e na Tabela I, a aplicação de um modelo de médias móveis é insuficiente para estes dados, uma vez que não apresentam uma tendência estável ao longo do tempo (Wooldridge, 2009, p. 380).

Figura 5 – Polígono da Frequência de Vendas por Loja em Classes de Amplitude 10



Fonte: Elaboração própria

Tabela I – Caracterização Global das Vendas por Loja e por classes

Loja	Classe modal	Média	Desvio padrão	Coef. de Variação	Kurtosis	Coef. de assimetria (γ)
1	120-129	131,50	36,56	0,278	1,106	0,641
2	140-149	145,38	40,02	0,275	0,958	0,692
3	160-169	169,13	46,35	0,274	1,820	0,800
4	280-289	302,40	83,08	0,275	0,604	0,577
5	250-259	249,24	67,97	0,273	1,342	0,734

Fonte: Elaboração própria

Segundo a Tabela I, verifica-se que as lojas com maior número de vendas (4 e 5) são também as que apresentam maior desvio padrão – o que é um indício de heterocedasticidade – resultando num coeficiente de variação bastante uniforme – Cf. 4.2. O excesso de *kurtosis* amostral é positivo demonstrando caudas densas e um pico alto e pouco extenso em torno da moda. A assimetria denota uma curva de rápido crescimento nos valores inferiores à média e de lento decréscimo após a mesma.


4.3.2. Inferência

A amostra revela diferenças significativas na comparação das médias de vendas diárias, o que era reconhecido graficamente. Com efeito a ANOVA apresenta um valor-p de 0,000

rejeitando a igualdade de médias entre grupos. Apesar de se tratar de uma estatística robusta, a significância da ANOVA passa pelos pressupostos de homocedasticidade e normalidade. O comportamento da amostra é heterocedástico entre as vendas das diferentes lojas, facto este confirmado pelo teste de Levene cujo valor-p resulta em 0,000, conforme Anexo B1. O teste Shapiro-Wilk rejeita a normalidade das vendas para as Lojas 1, 2 e 3 (Anexo B2). Contudo, no âmbito das séries temporais, a exigência de uma amostra elevada garante a aplicação do teorema do limite central e usar testes assintoticamente relevantes (Wooldridge, 2009, p. 377).

Verifica-se que o valor relativo das vendas varia de loja para loja mas mantém-se praticamente constante nos anos analisados. A Figura 6 ilustra bem a situação patente nas diferentes alturas das barras e no diminuto declive dos ajustamentos lineares.

Figura 6 – Percentagem de Vendas de Cada Loja ao Longo dos Anos



Fonte: Elaboração própria

Os testes estatísticos confirmam as observações realizadas (Anexo B3), rejeitando-se a permanência da quota de vendas apenas para a Loja 3. Tal situação aparenta ser paradoxal uma vez que as percentagens são linearmente dependentes e, por este facto, se são constantes para 4 lojas forçosamente deveria sê-lo para a quinta. Trata-se de idiossincrasia comum nos dados estatísticos e que deve ser simplesmente considerada irrelevante.

5. MODELAGEM E PREVISÃO

5.1. Construção do modelo


5.1.1. Modelo global vs. modelos individuais

Com o objetivo de modelizar convenientemente a procura diária foram consideradas 4 situações distintas:

- 5 modelos, um para cada ponto de venda;
- 1 modelo global com variáveis artificiais de forma a distinguir as 5 lojas (situação esta equivalente à anterior);
- agrupar lojas com vendas semelhantes (*clustering*), nomeadamente {Lojas 1, 2, e 3}, {Loja 4}, {Loja 5} – Cf. B1, fig. 6
- 1 modelo global.

Para averiguar qual a situação mais adequada na construção do modelo a primeiramente deve-se analisar as variações da quota de vendas de cada loja (Figura 7 e Tabela II):

Figura 7 – Percentagem de Vendas Diária de Cada Loja Com Regressão Linear



Fonte: Elaboração própria

Tabela II – Média e Intervalos de Confiança a 95% para a Percentagem de Vendas Diárias

	Média \pm Margem de erro	Intervalo de Confiança 95%	
Loja 1	13,14 \pm 0,04 (%)	13,10 %	13,18 %
Loja 2	14,58 \pm 0,06 (%)	14,52 %	14,64 %
Loja 3	16,96 \pm 0,06 (%)	16,90 %	17,01 %
Loja 4	30,32 \pm 0,08 (%)	30,24 %	30,41 %
Loja 5	25,00 \pm 0,08 (%)	24,93 %	25,08 %

Fonte: Elaboração própria

Destaca-se a pequena margem de erro da quota mercado interna ao Trigo da Aldeia apesar de a Figura 7 exibir alguma oscilação. Remetendo-se para a caracterização da amostra (4.3.2 e Figura 6), a média anual da percentagem de vendas apresenta uma pequena variação.


Deste modo a construção de um modelo global para a produção diária não só é plausível como obedece aos seguintes critérios:

- Clareza na compreensão do modelo perante outros com mais variáveis artificiais;
- Facilidade na interpretação das variáveis nomeadamente na análise *ceteris paribus*;
- Adequação à realidade objetiva, pois, existindo uma só fábrica a produzir, deve existir uma só previsão, sendo esta mais fácil de realizar do que 5 previsões;
- Coerência com a pequena variação da percentagem (Figura 6) e diminutas margens de erro (Tabela II).

5.1.2. Variáveis Explicativas

Segundo a Figura 8, verificam-se vendas inferiores à segunda-feira, um patamar uniforme de terça a sexta e subidas nos sábados e domingos. A presença de *outliers* severos (picos de vendas) na segunda, sexta e sábado está relacionada com o facto de os dias de maiores vendas (24 e 31 de dezembro) terem acontecido nesses dias da semana (respetivamente em 2012, 2011 e 2010).


Figura 8 – Total Diário de Vendas Como Função do Dia-de-semana e Recodificação



Fonte: Elaboração própria

A aglomeração de alguns dias e dos feriados com os domingos permite recodificar as 8 variáveis em 4. No modelo, e para evitar a armadilha das variáveis artificiais, serão usadas 3.


Figura 9 – Média das Vendas ao Longo do Mês Com e Sem os Dias 24 e 31 de Dezembro



Fonte: Elaboração própria

A Figura 9 ilustra os consumos ao longo do mês assim como os picos de 24 e 31 de dezembro típicos dessa quadra festiva. Note-se que o começo da semana nem sempre coincide com o começo do mês. Pode-se constatar que este padrão demonstra um consumo regular nas primeiras 18 dias (aprox. 2 / 3 semanas) que decai no decurso da 3ª e sobe junto ao fim do mês. O padrão obtido na Figura 9 b) pode ser sobreposto nas diversas semanas ao longo do ano (Figura 10) verificando que, dentro de cada vez, existe um comportamento cíclico:

Figura 10 – Sobreposição Entre a Média Semanal de Vendas e o Padrão Mensal



Fonte: Elaboração própria

As maiores divergências verificadas na Figura 10 são as seguintes:

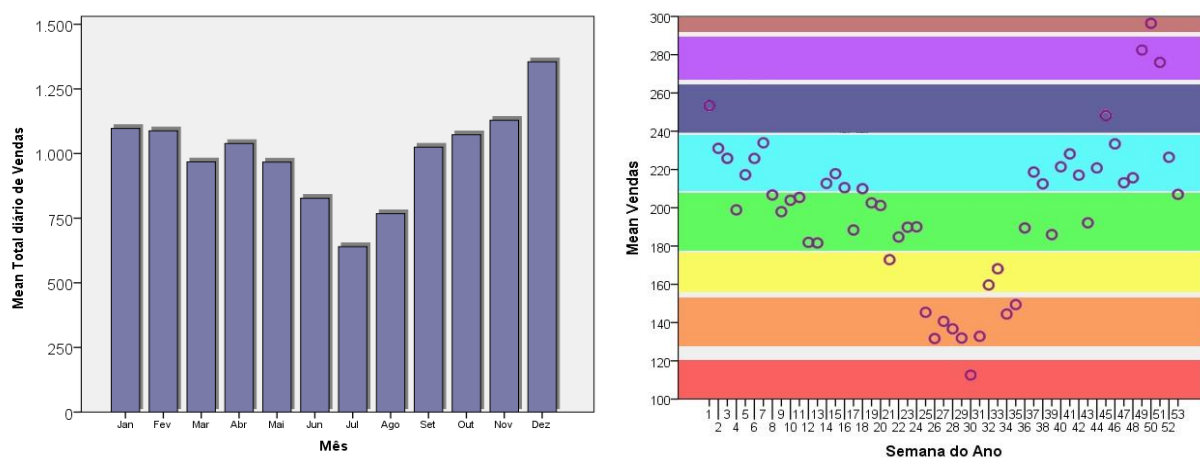
Tabela III – Desajustes entre o Padrão Mensal e as Vendas ao Longo das Semanas

- | | |
|---|---|
| ① | 1ª semana do ano – o pico de vendas correspondente a esta altura do ano; |
| ② | 7ª semana – a última de fevereiro, pois o padrão mensal de 31 dias desajusta-se dos 28/29 dias deste mês; |
| ③ | 26ª semana – no meio/fim de junho, correspondente às férias escolares e começo do verão cuja diminuição de vendas se afasta significativamente do aumento esperado para a 4ª semana do mês; |
| ④ | 33ª – a primeira de agosto cujo pico de vendas pode ser explicado pela diminuição da concorrência que encerra para férias; |
| ⑤ | 36ª e 37ª – a primeira quinzena de setembro, correspondente ao final do período de férias; |
| ⑥ | 45ª – a primeira de novembro, devido à diminuição da temperatura; |
| ⑦ | 50ª – a transição de novembro/dezembro; |
| ⑧ | 52ª a 53ª – pico de vendas do Natal e quebra na última semana do ano que contraria o padrão de que da 3ª para a 4ª semana há um aumento. |

Fonte: Elaboração própria

As semanas 26, 36 e 37 são concordantes com o período de férias escolares, e esta alteração sente-se a nível do consumo dos artigos de pastelaria. Estes dados associados, a primeira e última semanas do ano e o padrão de consumo, induzem uma análise semanal. Destaca-se ainda que, dependendo do dia da semana em que calha o início do ano, o dia 24 de dezembro, o maior pico de vendas, surge na semana 50 ou na 51, diluindo o máximo – o que motiva a utilização de variáveis específicas para esta quadra festiva (Figura 11).

Figura 11 – Comparação Entre as Médias de Vendas Mensais e as Médias Semanais



Fonte: Elaboração própria

Uma análise de vizinhos mais próximos permite identificar 8 zonas de aglomeração das médias de vendas correspondentes às faixas coloridas. Na quadra festiva o consumo é tão variado que houve necessidade de introduzir mais 2 variáveis reduzindo-se as 53 semanas a 10 regiões, i.e., 9 variáveis artificiais no modelo. Refira-se que as zonas de *clustering* dos dados têm a amplitude muito semelhante – o que traduz um certo equilíbrio na partição.

Para investigar acerca de uma possível influência do clima incluiu-se os dados da temperatura e da precipitação diárias no modelo. Sendo aparentemente significativas, revelaram a sua natureza espúria quando os termos de tendência e sazonalidade foram considerados no modelo. Um dado empírico verificado foi que a ocorrência de um dia chuvoso durante a época balnear marcava um pico nas vendas pelo que se construiu a seguinte variável artificial – conforme Secção 4.2.1 *Stockout* observado:

$$Chuva\ no\ verão = \begin{cases} 1, & \text{se ocorrer precipitação em julho ou agosto} \\ 0, & \text{caso contrário} \end{cases}$$

Esta variável já se revelou estatisticamente significativa (Anexo D).

5.1.3. Testes ao Modelo

Todos os *outputs* dos testes estatísticos efetuados estão incluídos no Anexo D.

O teste de White *special* vem confirmar os testes de Levene realizados na descrição da amostra – conforme secção 4.3.2 da Tese.

Os testes de autocorrelação buscam encontrar um padrão habitualmente associado a uma má especificação do modelo (Murteira, Ribeiro, Silva, A., & Pimenta, 2010, p. 615). Para investigar esta ocorrência, e devido à existência de uma regularidade semanal, buscou-se um desfasamento de pelo menos 7 ordens tendo-se considerado duas adicionais. A elevada correlação entre a variável dependente desfasada ($vendas_{t-3} \dots vendas_{t-9}$) e as variáveis semanais sugerem que não se considerem mais do que 2 desfasamentos, i.e., as vendas de hoje têm como variáveis exógenas as vendas de ontem e anteontem. Outro critério usado foi a comparação com o termo de tendência. Todos os desfasamentos de ordem igual ou superior a 3 apresentam um coeficiente inferior ao de t , e o produto entre o coeficiente e o valor da variável é ainda mais negligenciável. Refira-se ainda que a inclusão de demasiadas variáveis correlacionadas entre si levanta problemas relacionados com a exogeneidade das mesmas e a nível da estimação dos erros. A exclusão destes desfasamentos aumenta a correlação entre a *temperatura* e as variáveis *chuva no verão* (artificial) e a tendência mostrando o caráter espúrio da primeira, sendo por isso removida do modelo.

Uma situação típica de séries temporais autocorrelacionadas é a eventual violação da primeira hipótese de regressão que consiste na estacionaridade e fraca dependência da série. Wooldridge (2009, p. 378) refere que um coeficiente de autocorrelação inferior a 0,8 permite evitar a diferenciação requerida pelas séries integradas de ordem 1 – tendo-se apurado o valor

de 0,36. Deste modo, o modelo linear é assintoticamente válido não havendo necessidade de recorrer aos testes de co-integração e a previsão não carece de um modelo de correção de erro.

5.1.4. Reformulação do Modelo

De acordo com os resultados dos testes obtidos, apresenta-se a versão do modelo que será utilizado para a previsão, tratando-se o mesmo de um modelo de regressão linear com tendência e sazonalidade, autoregressivo de 2ª ordem (AR(2)) e com estimação da máxima verossimilhança heterocedástico-consistente de White:

$$vendas_t =$$

$$\hat{\beta}_0 + \hat{\beta}_{dia} + \hat{\beta}_{epoca} + \hat{\beta}_3 \cdot \delta_{chuva_verão} + \hat{\beta}_4 \cdot t + \hat{\alpha}_1 \cdot vendas_{t-1} + \hat{\alpha}_2 \cdot vendas_{t-2} + \hat{u}_t$$

Tabela IV – Estimação do Modelo com Estatística Robusta de White

Descrição	Parâmetro	Estimativa	Erro padrão robusto	95% IC	
				Inferior	Superior
	(interseção)	1473,904	77,774	1321,325	1626,484
	Chuva_no_verão	105,446	24,266	57,839	153,052
Sazonalidade (dia da semana)	Seg	-535,068	13,306	-561,171	-508,964
	Ter_a_Sex	-266,715	11,911	-290,083	-243,347
	Sáb	-70,558	13,469	-96,982	-44,133
Sazonalidade (ao longo do ano com especificação da quadra festiva)	Sem_A	-990,029	65,156	-1117,855	-862,202
	Sem_B	-961,969	65,106	-1089,697	-834,241
	Sem_C	-933,462	63,220	-1057,490	-809,434
	Sem_D	-854,440	62,294	-976,651	-732,230
	Sem_E	-799,814	61,541	-920,547	-679,081
	Sem_F	-770,696	62,656	-893,617	-647,776
	Sem_G	-675,831	64,447	-802,266	-549,396
	Sem_H	-732,247	71,492	-872,502	-591,991
	Sem_I	-185,570	243,148	-662,587	291,447
Autoregressivo AR(2)	Vendas _{t-1}	,359	,037	,287	,431
	Vendas _{t-2}	,186	,015	,156	,216
Tendência	t	,071	,009	,053	,090

Fonte: Elaboração própria

O modelo globalmente tem um carácter significativo (valor-p = 0,000) e explica 85,6% das variações das vendas registadas. Todas as variáveis são também significativas exibindo um valor-p igual ou inferior a 1%.

5.1.5. Análise Retroativa ao Modelo de Previsão

O objetivo deste teste é comparar a aplicação do modelo de previsão aos dados observados. Por outras palavras, para além dos testes t e F à bondade do ajuste, pretende-se nesta secção avaliar as implicações futuras da aplicação do modelo simulando a sua utilização no passado.


Em torno da previsão pontual construiu-se um IP, considerando-se o extremo superior para efeitos da tomada de decisão acerca da produção. A escolha do grau de confiança do IP prende-se com uma solução de compromisso entre a quantidade de sobras e o *stockout* que gera.

Tabela V – Sobras Médias e *Stockout* Médio por Aplicação Retroativa do Modelo

Grau de Confiança	Sobras (por dia e por loja)		<i>Stockout</i> (por dia e por loja)		
	Média geral	Média sobras	Ocorrências percentagem	média de bolos por vender	média de bolos por vender <i>stockout</i>
40%	13,39	17,87	320 / 25,20%	2,56	10,15
45%	14,56	18,40	267 / 21,02%	2,21	10,51
50%	15,84	19,09	218 / 17,17%	1,91	11,12
55%	17,25	20,05	179 / 14,09%	1,64	11,67
60%	18,80	21,14	142 / 11,18%	1,42	12,69
65%	20,52	22,63	120 / 9,45%	1,22	12,88
70%	22,45	24,33	100 / 7,87%	1,04	13,20

Fonte: Elaboração própria


Nesta tabela colocou-se a média geral e condicionada, ou seja, a média de sobras relativamente a todos os dias de produção e a média de sobras considerando apenas os dias em que estas efectivamente ocorrem. *Mutatis mutandis* para o número de bolos por vender.

Figura 12 – Sobras Médias e *Stockout* Médio por Aplicação Retroativa do Modelo

Fonte: Elaboração própria

É de notar-se a monotonia oposta entre a média geral e a média condicionada de bolos por vender. Esta situação traduz o seguinte: ao aumentar o nível de confiança do IP, o limiar superior cresce diminuindo as quantidades de *stockout*. Como diminuem o número de dias em que tal se verifica, o rácio revela um crescimento.

Perante estes dados, escolheu-se o $IP_{55\%}$ como referência pois é uma solução de compromisso adequada surgindo antes de um limiar de crescimento no *stockout* condicionado. Deste modo o total de sobras nestes 3 anos e meio teria sido de 109358 em vez dos 171728 que realmente se verificaram correspondendo a uma diminuição de 36,3%. O *stockout* teria tido uma média de 11,67 bolos e teria ocorrido 17,2 vezes por ano em cada loja; dada a distribuição do consumo das lojas do Trigo da Aldeia, os valores correspondem a vendas efectuadas depois das 20h cujo impacto perante o consumidor sai amortecido.

Figura 13 – Comparação entre os valores observados e os valores ajustados com $IP_{55\%}$ 

Fonte: Elaboração própria

5.2. Previsão One-Step-Ahead

A previsão realizada é *one-step-ahead*, ou seja, para não haver acumulação de erros de previsão optou-se por efetuar uma aplicação do modelo aos valores observados. Caso contrário, a autocorrelação desta série temporal obrigaria a utilizar valores previstos para realizar a previsão seguinte, e assim sucessivamente.

A Tabela VI apresenta os valores dos regressores utilizados e os da previsão pontual ao longo dos 31 dias do mês de julho.

Tabela VI – Previsão da Procura para o Mês de Julho com Base no Modelo Obtido

DADOS		REGRESSORES							PREVISÃO
Data	dia sem.	chuva verão	Sazonalidade					Tendência	
			2	3 a 6	sáb	A	B	t	
13 jun 29	sáb	0	0	0	1	0	1	1276	995
13 jun 30	dom	0	0	0	0	0	1	1277	976
13 jul 01	seg	0	1	0	0	0	1	1278	603,1
13 jul 02	ter	0	0	1	0	0	1	1279	734,1
13 jul 03	qua	0	0	1	0	1	0	1280	683,7
13 jul 04	qui	0	0	1	0	1	0	1281	690,1
13 jul 05	sex	0	0	1	0	1	0	1282	683,1
13 jul 06	sáb	0	0	0	1	1	0	1283	878,0
13 jul 07	dom	0	0	0	0	1	0	1284	1017,3
13 jul 08	seg	0	1	0	0	1	0	1285	568,6
13 jul 09	ter	0	0	1	0	1	0	1286	701,8
13 jul 10	qua	0	0	1	0	1	0	1287	666,2
13 jul 11	qui	0	0	1	0	1	0	1288	678,3
13 jul 12	sex	0	0	1	0	1	0	1289	676,1
13 jul 13	sáb	0	0	0	1	1	0	1290	873,8
13 jul 14	dom	0	0	0	0	1	0	1291	1015,0
13 jul 15	seg	0	1	0	0	1	0	1292	567,4
13 jul 16	ter	0	0	1	0	1	0	1293	701,5
13 jul 17	qua	0	0	1	0	1	0	1294	666,4
13 jul 18	qui	0	0	1	0	1	0	1295	678,8
13 jul 19	sex	0	0	1	0	1	0	1296	676,8
13 jul 20	sáb	0	0	0	1	1	0	1297	874,6
13 jul 21	dom	0	0	0	0	1	0	1298	1015,9
13 jul 22	seg	0	1	0	0	1	0	1299	568,4
13 jul 23	ter	0	0	1	0	1	0	1300	702,5
13 jul 24	qua	0	0	1	0	1	0	1301	667,5
13 jul 25	qui	0	0	1	0	1	0	1302	679,9
13 jul 26	sex	0	0	1	0	1	0	1303	677,9
13 jul 27	sáb	0	0	0	1	1	0	1304	875,7
13 jul 28	dom	0	0	0	0	1	0	1305	1017,0
13 jul 29	seg	0	1	0	0	1	0	1306	569,5
13 jul 30	ter	0	0	1	0	1	0	1307	703,6
13 jul 31	qua	0	0	1	0	1	0	1308	668,5

Fonte: Elaboração própria

Nota: os valores das vendas para 29 e 30 de junho não fazem parte da previsão mas figuram na tabela por se tratarem de regressores para o modelo uma vez que este é AR(2).

Em torno da previsão realizada (pontual) utilizar-se-á o intervalo de acordo com o nível de confiança de 55%, adotando-se o extremo superior para comparação com os valores de julho.

5.2.1. Testes ao Modelo de Previsão

A Tabela VII foi construída com base no IP de 55% e diariamente foram registados os valores das vendas, das sobras e os que se obteriam por aplicação do modelo.

Tabela VII – IP55% e Comparação com as Vendas Registadas e os Valores Observados

MODELO			OBSERVADO	
IP _{55%}		Sobras / <i>Stockout</i>	Vendas	Sobras
524,9	681,2	93,216	588	105
656	812,2	86,174	726	103
605,6	761,9	67,866	694	118
612	768,2	22,235	746	110
605	761,2	7,2352	754	101
799,9	956,1	106,07	850	103
939,3	1095	63,313	1032	116
490,4	646,7	2,7309	644	116
623,7	779,9	11,92	768	103
588,1	744,4	-23,63	768	120
600,2	756,5	66,451	690	108
598	754,2	88,247	666	106
795,7	951,9	121,86	830	103
937	1093	63,001	1030	112
489,3	645,6	95,616	550	105

MODELO			OBSERVADO	
IP _{55%}		Sobras / <i>Stockout</i>	Vendas	Sobras
623,3	779,6	65,587	714	95
588,3	744,5	64,539	680	115
600,7	756,9	4,9471	752	113
598,7	755	116,95	638	103
796,6	952,7	54,705	898	97
937,9	1094	181,93	912	93
490,3	646,6	4,6035	642	92
624,4	780,6	120,61	660	87
589,3	745,6	33,588	712	102
601,8	758	38,011	720	75
599,8	756	4,0273	752	82
797,7	953,8	59,786	894	95
939	1095	85,016	1010	98
491,4	647,7	79,691	568	107
625,5	781,7	105,7	676	97
590,4	746,7	254,68	492	101

Fonte: Elaboração própria

O valor negativo das sobras representa um *stockout* significando que no dia 10 de julho ficariam por vender 23,6 bolos. A média das sobras seria de 72,34 artigos contra a média registada de 102,6, representando uma diminuição de 29,5%. Perante esta situação, contabiliza-se um saldo positivo de €393,00 quando se realiza a previsão através do modelo.

6. TRANSPORTE

6.1. Análise do melhor percurso

O problema do transporte por vezes é de análise complexa, mas é uma etapa basilar da logística e da gestão do produto. É nesta vertente que importa ser considerado, nomeadamente no processo de realocação das sobras do produto, transportando o excesso de uma(s) loja(s) para suprir as faltas de outra(s), sendo um complemento à previsão das vendas, no sentido de fazer o melhor ajuste possível entre a oferta e a procura.

A escolha do melhor percurso é um processo NP complexo pois pode envolver diversos fatores, desde os pontos de paragem até constrangimentos de sentido, velocidade circulação, horário, etc., pelo que é abordado de uma forma heurística, não só a nível teórico, mas sobretudo pelos conhecidos *softwares* de GPS, sistemas andróides e *Google maps* utilizados nesta análise cujos cálculos assentam no algoritmo Dijkstra (Dijkstra, 1959).

O constrangimento de que só uma fábrica fornece as 5 lojas do grupo – situada naquela que foi referida como 'Loja 4' – obriga a um circuito fechado, constituindo o denominado ciclo hamiltoniano cuja regra heurística remete para um padrão tipo gota, conforme Figura 14 (Ballou, 1992, pp. 488, 489).

Figura 14 – Melhor percurso passando pelas 5 lojas Trigo d'Aldeia (ciclo hamiltoniano)



Fonte: *Google Maps* e elaboração própria

O sentido de circulação é indiferente a nível gráfico e depende da relação sobras/carências sendo que a fábrica (Loja 4) produz sempre em excesso. De acordo com esta dualidade excesso/falta considerada, o levantamento exaustivo de todas as hipóteses revela 16 situações possíveis que são colmatadas com os percursos $4 \rightarrow 1 \rightarrow 5 \rightarrow 2 \rightarrow 3 \rightarrow 4$ ou pequenas variações, e os respetivos inversos. A título ilustrativo, pode supor-se que as lojas 1 e 2 têm carência de produto enquanto as lojas 3 e 5 têm excesso. Neste caso, o trajeto é uma pequena variação $4 \rightarrow 3 \rightarrow 1 \rightarrow 5 \rightarrow 2 \rightarrow 4$ realizando-se os respetivos movimentos de recolha ou abastecimento.

A situação adequada, ou seja, a loja não tem produto nem falta, nem em excesso, só é relevante na gestão do transporte quando se trata da Loja 5 por ser o vértice afastado do aglomerado das restantes lojas (Figura 15). No percurso $4 \rightarrow 5$ a carrinha passa sempre pela Loja 1. Se não houver necessidade de efetuar uma paragem na Loja 5, a rota de redistribuição do produto é simplesmente $(4 \rightarrow 1 \rightarrow 3 \rightarrow 2 \rightarrow 4)$ ou o seu inverso.

Figura 15 – Percurso excluindo a Loja 5



Fonte: *Google Maps* e elaboração própria

6.2. Considerações Finais sobre o Transporte

6.2.1. Horário de redistribuição

O horário para a realização do transporte deve ser feito tendo em conta diversas condições, uma vez que existe um período do dia mais adequado para a realização do mesmo. Este não deve ser feito demasiado cedo, pois quanto mais tarde melhor será a perceção do volume de


vendas mas, a realocação de produto não pode ser realizada para além do tempo adequado impedindo os pontos de venda de dar a resposta adequada às necessidades. A prática demonstra que é entre as 15h30-16h00 o melhor momento para fazer a redistribuição, pois a esta hora já se tem uma ideia bem concreta dos consumos do dia, conseguindo-se também fazer face ao período da tarde com mais afluência que é 16h30-17h30.

6.2.2. Análise das quantidades para redistribuição

Perante a relativa proximidade das diversas lojas Trigo d'Aldeia basta um pequeno número de quantidade a redistribuir para justificar o transporte. Com efeito, o frete implica uma distância de 11,2 Km correspondente a um custo fixo estimado de €1,41 e a um tempo variável entre 40 a 70 minutos, dependendo do trânsito rodoviário e das quantidades para carga e descarga. O custo foi apurado com base nas médias de consumo de combustível.

Cada bolo vendido gera, em média, um lucro provisório de €0,40, sendo negligenciável o aumento do custo do transporte por bolo. Conclui-se deste modo que basta apenas a venda suplementar de 4 bolos para justificar a redistribuição do produto Figura 16.

Figura 16 – Custo do transporte vs. Lucro provisório de cada bolo



Fonte: Elaboração própria

A análise da Figura 16 pode ser de grande utilidade para o futuro caso se verifique a tendência de crescimento que a empresa tem registado desde a sua origem, isto porque se os pontos de venda aumentarem, a importância destes fatores aumenta exponencialmente.

7. CONCLUSÕES E RECOMENDAÇÕES

Na compreensão da previsão, como ferramenta importantíssima para a empresa é igualmente fundamental ter presente que o modelo não é um programa de computador que simplesmente indica a quantidade a produzir, mas sim um auxiliar à gestão que deve procurar incluir os diversos setores da empresa (Moon *et al*, 1998). Estes mesmos autores destacam o ónus da previsão pois quando este recai sobre o departamento de vendas, a tendência é a de subavaliar, com o objetivo de o funcionário mostrar que conseguiu cumprir com o objetivo diário, levando a situações de *stockout* com todo o impacto negativo que tem perante o cliente.

Neste contexto, deve entender-se que a previsão:

- É uma ação da gestão para o planeamento logístico que envolve toda a empresa;
- É uma fonte de motivação para os vendedores, no sentido de ser utilizada para estabelecer uma meta realística para as vendas do dia – sem no entanto confundir a previsão em si com o objetivo de vendas;
- É um processo dinâmico que deve ser revisto periodicamente para maior precisão.

Conclui-se a questão de investigação foi respondida pois o modelo encontrado prevê dentro de uma margem de erro aceitável, a procura, sendo uma ferramenta fiável para o planeamento da produção.

Em particular, a realização diária da previsão durante o mês de julho de 2012 demonstrou um resultado positivo de €393,00 para a empresa Trigo da Aldeia.

Destaca-se ainda que a capacidade de previsão do modelo não surge em detrimento da sua compreensão, tornando-se assim numa ferramenta de elevada utilidade.

Finalizando, o autor gostaria de constatar que todo um panorama se desvendou no campo da gestão industrial e planeamento, com ramificações a nível da gestão sendo que, se a investigação futura poderá mostrar a previsão como ferramenta para a implantação de novos produtos e novas tendências que muitas vezes surgem em tempos de mudança.

A união da modelização à intuição demonstrou a sua utilidade e sugere-se que este elo seja reforçado em trocas de informação útil dentro da empresa (por exemplo, para melhoria do modelo de previsão) e para fora – e.g, em ações promocionais e marketing que ajudem a escoar o produto, diminuindo ainda mais o desperdício, cumprindo com o papel de aumentar o lucro da empresa num contexto de produção sustentada.


REFERÊNCIAS BIBLIOGRÁFICAS

- Anderson, E. W. (1998). Customer Satisfaction and Word of Mouth. *Journal of Service Research*.
- Ballou, R. H. (1992). *Business Logistics Management* (3 ed.). Prentice Hall, Inc.
- Bunn, D. (1984). *Applied Decision Analysis*. McGraw-Hill.
- Caiado, J. (2011). *Métodos de Previsão em Gestão - Com aplicações em Excel*. Lisboa: Edições Sílabo, Lda.
- Cooper, W., Homem-de-Mello, T., & Kleywegt, A. (2006). Models of the Spiral-Down Effect in Revenue Management. *Operations Research*.
- Dijkstra, E. W. (1959). A Note on Two Problems in Connexion with Graphs. *Numerische Mathematlk*.
- Dimensional Research - ZenDesk. (2013). *Customer Service and Business Results: A survey of customer service from mid-size compoanies*. Marketing Charts.
- Fisher, M., Hammond, J., Obermeyer, W., & Raman, A. (May-June de 1994). Making supply meet demand in an uncertain world. *Harvard Business Review*.
- Gilliland, M. (2003). Fundamental Issues in Business Forecasting. *Journal of Business Forecasting*.
- Gillin, P. (2007). *The new influencers: A marketer's guide to the new social media*. Sanger, USA: Quill Driver Books.
- Hill, C. W., & Jones, G. R. (2008). *Strategic Management Theory*. South-Western Cengage Learning.
- Hoshmand, A. R. (2010). *Business Forecasting - A Practical Approach* (2nd ed.). Routledge.
- Hughes, M. C. (2001). Forecasting Practice: Organisational Issues. *Journal of the Operations Management Society*.
- Mangold, W. G., & Faulds, D. J. (2009). Social media: The new hybrid element of the promotion mix. *Business Horizons*.
- Moon, M. A., Mentzer, J. T., Smith, C. D., & Garver, M. S. (September-October de 1998). Seven Keys to Better Forecasting. *Business Horizons*.

- Morgado, L. (2009). *Gestão e Planeamento da Produção de Materiais de Construção: Um Projeto de Melhoria*. Tese de Mestrado, ISEG, Mestrado em Ciências Empresariais.
- Murteira, B. (1996). *Decisão Estatística para Gestores*. Lisboa: Universidade Autónoma de Lisboa.
- Murteira, B., Müller, D., & Turkman, K. (1993). *Análise de Sucessões Cronológicas*. Lisboa: McGraw-Hill.
- Murteira, B., Ribeiro, C. S., Silva, A., J., & Pimenta, C. (2010). *Introdução à Estatística*. Escolar Editora.
- Penrose, R. (1997). *A Mente Virtual*. Lisboa: Gradiva - Publicações, Lda.
- Reis, E. (2009). *Estatística Descritiva* (7ª ed.). Lisboa: Edições Sílabo, Lda.
- Reis, R. L. (2008). *Manual da Gestão de Stocks - Teoria e Prática* (2ª ed.). Lisboa: Editorial Presença.
- Saffo, P. (July-August de 2007). Six Rules fo Effective Forecasting. *Harvard Business Review*.
- Stefanescu, C. (2009). *Multivariate Demand: Modeling and Estimation from Censored Sales*. London Business School, Management Science and Operations.
- Wecker, W. (1978). Predicting Demand From Sales Data in the Presence of Stockouts. *Management Science*.
- Wooldridge, J. (2009). *Introductory Econometrics - A Modern Approach* (4th ed.). South-Western Cengage Learning.
- Zhu, F., & Zhang, X. (2010). Impact of Online Consumer Reviews on Sales: The Moderating Role of Product and Consumer Characteristics. *Journal of Marketing*.
- Zinn, W., & Liu, P. (2001). Consumer response to retail stockouts. *Journal of Business Logistics*, 22.


ANEXO A. (4.3 – CARACTERIZAÇÃO DA PROCURA)

Figura 1 – Polígono da Frequência de Vendas por Loja



Fonte: Elaboração própria

Figura 2 - Histograma e Caixa-de-bigodes das Vendas Globais



Fonte: Elaboração própria

Tabela I - Caracterização das Vendas Globais


N	6350
Min.	47
Max.	747
Mean	199,16
Std. Dev.	87,56
Skew.	1,083
Std. Error	0,031
Kurtosis	1,280
Std. Error	0,061
Kolmogorov-Smirnov	
Stat.	0,107
Sig.	0,000

Tabela II - Caracterização Global das Vendas por Loja

Descriptive Statistics									
	N	Minimum	Maximum	Mean	Std. Deviation	Skewness		Kurtosis	
	Statistic	Statistic	Statistic	Statistic	Statistic	Statistic	Std. Error	Statistic	Std. Error
Vendas - Loja 1	1270	47	316	130,99	36,315	,652	,069	1,188	,137
Vendas - Loja 2	1270	60	347	145,09	40,227	,730	,069	1,132	,137
Vendas - Loja 3	1270	57	449	168,70	46,309	,821	,069	1,917	,137
Vendas - Loja 4	1270	120	747	302,25	83,980	,666	,069	1,080	,137
Vendas - Loja 5	1270	92	610	248,77	67,950	,724	,069	1,293	,137
Valid N (listwise)	1270								


Fonte: Elaboração própria

Figura 3 – Vendas por Loja ao Longo do Tempo



Fonte: Elaboração própria


Figura 4 – N. Médio de Produtos Colocado à Venda por Loja ao Longo do Tempo



Fonte: Elaboração própria

ANEXO B. (4. 3 – CARACTERIZAÇÃO DA PROCURA)

Figura 5 – Flutuação do Consumo ao Longo da Semana



Universo: Lares de Portugal Continental que compraram no retalho organizado

Período: 1º Semestre 2005

Fonte: Marktest

1. Testes Globais

Tabela III – Teste de Levene para a Homogeneidade de Variâncias das Vendas

Test of Homogeneity of Variances

Vendas

Levene Statistic	df1	df2	Sig.
238,993	4	6345	,000


Fonte: Elaboração própria (output do SPSS)

Tabela IV – ANOVA para a Comparação das Médias de Vendas das Lojas

		Sum of Squares	df	Mean Square	F	Sig.
Between Groups	(Combined)	27416618,10	4	6854154,524	2045,867	,000
	Linear Term	19587758,28	1	19587758,28	5846,666	,000
	Deviation	7828859,814	3	2609619,938	778,934	,000
Within Groups		21257300,02	6345	3350,244		
Total		48673918,12	6349			

Fonte: Elaboração própria (output do SPSS)

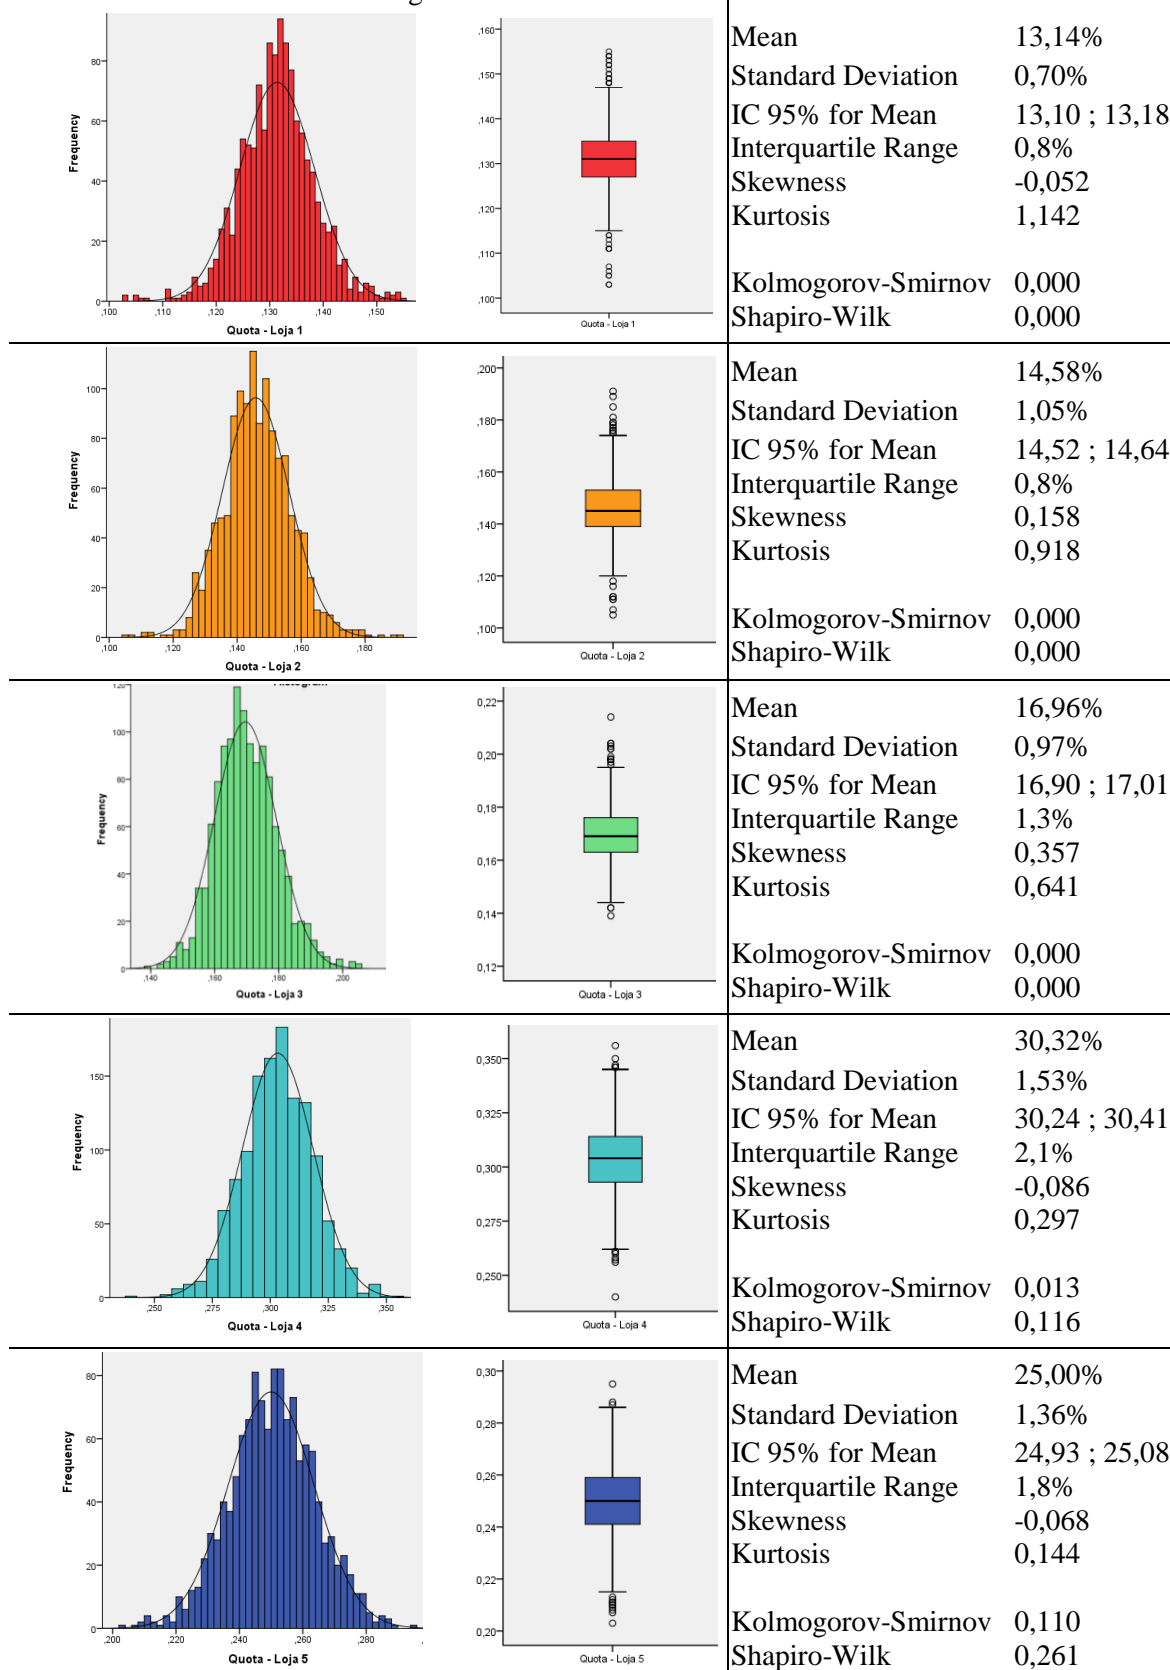
Figura 6 – Médias de Vendas Globais por Loja e Possível Clustering



Fonte: Elaboração própria (output do SPSS)

2. Testes às Vendas por Loja

Figura 7 - Histograma das Quotas de Vendas e Caixas-de-bigodes



3. Testes às Percentagens Anuais de Vendas por Loja

As percentagens diárias constituem uma inferência específica para a construção de um modelo global que seja comum à produção para as 5 lojas.

Tabela VI – ANOVAs Referentes à Vendas das Lojas ao Longo dos Anos

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,000	1	,000	,302	,583 ^b
	Residual	,061	1268	,000		
	Total	,061	1269			

a. Dependent Variable: Quota - Loja 1

b. Predictors: (Constant), Ano

Fonte: Elaboração própria (*output* do SPSS)

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,000	1	,000	,331	,565 ^b
	Residual	,140	1268	,000		
	Total	,140	1269			

a. Dependent Variable: Quota - Loja 2

b. Predictors: (Constant), Ano

Fonte: Elaboração própria (*output* do SPSS)

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,001	1	,001	12,499	,000 ^b
	Residual	,119	1268	,000		
	Total	,120	1269			

a. Dependent Variable: Quota - Loja 3

b. Predictors: (Constant), Ano

Fonte: Elaboração própria (*output* do SPSS)

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,000	1	,000	1,855	,173 ^b
	Residual	,297	1268	,000		
	Total	,297	1269			

a. Dependent Variable: Quota - Loja 4

b. Predictors: (Constant), Ano

Fonte: Elaboração própria (*output* do SPSS)

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,003	1	,003	15,767	,000 ^b
	Residual	,230	1268	,000		
	Total	,233	1269			

a. Dependent Variable: Quota - Loja 5

b. Predictors: (Constant), Ano

Fonte: Elaboração própria (*output* do SPSS)

ANEXO C. (5.1 – CONSTRUÇÃO DO MODELO)

Tabela VII – Análise da Tendência

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,260 ^a	,068	,067	260,500

a. Predictors: (Constant), trend

b. Dependent Variable: Total diário de Vendas

Coefficients^a

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
	B	Std. Error	Beta			Tolerance	VIF
1 (Constant)	874,388	14,628		59,774	,000		
trend	,191	,020	,260	9,582	,000	1,000	1,000

a. Dependent Variable: Total diário de Vendas

Fonte: Elaboração própria (*output* do SPSS)

ANEXO D. (5.1 – CONSTRUÇÃO DO MODELO)

Tabela VIII – *Output* do modelo 1 – Sem tendência; com: sazonalidade, temperatura e precipitação como regressores

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,859 ^a	,737	,734	138,895

a. Predictors: (Constant), Quadra Festiva 2, Quadra Festiva 1, Ter-Sex (Não Fer), Semanas tipo G, Semanas tipo A, Semanas tipo B, Semanas tipo C, Precip, Semanas tipo F, Temp, Semanas tipo D, Seg (Não Fer), Sáb (Não Fer), Semanas tipo E

b. Dependent Variable: Total diário de Vendas

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	64453288,41	14	4603806,315	238,641	,000 ^b
	Residual	22957193,11	1190	19291,759		
	Total	87410481,52	1204			

a. Dependent Variable: Total diário de Vendas

b. Predictors: (Constant), Quadra Festiva 2, Quadra Festiva 1, Ter-Sex (Não Fer), Semanas tipo G, Semanas tipo A, Semanas tipo B, Semanas tipo C, Precip, Semanas tipo F, Temp, Semanas tipo D, Seg (Não Fer), Sáb (Não Fer), Semanas tipo E

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
		B	Std. Error	Beta			Lower Bound	Upper Bound
1	(Constant)	2239,406	81,431		27,501	,000	2079,642	2399,171
	Temp	-4,779	,959	-,081	-4,985	,000	-6,660	-2,898
	Precip	-,938	,715	-,020	-1,312	,190	-2,340	,465
	Seg (Não Fer)	-444,073	14,457	-,568	-30,717	,000	-472,437	-415,709
	Ter-Sex (Não Fer)	-326,565	11,042	-,603	-29,575	,000	-348,229	-304,901
	Sáb (Não Fer)	-129,167	14,450	-,166	-8,939	,000	-157,517	-100,817
	Semanas tipo A	-1261,583	82,146	-1,139	-15,358	,000	-1422,750	-1100,417
	Semanas tipo B	-1183,486	82,106	-1,062	-14,414	,000	-1344,575	-1022,397
	Semanas tipo C	-1088,257	81,884	-1,062	-13,290	,000	-1248,910	-927,603
	Semanas tipo D	-947,915	80,723	-1,565	-11,743	,000	-1106,290	-789,541
	Semanas tipo E	-853,404	80,593	-1,544	-10,589	,000	-1011,524	-695,284
	Semanas tipo F	-790,753	81,614	-,787	-9,689	,000	-950,876	-630,630
	Semanas tipo G	-531,774	82,205	-,439	-6,469	,000	-693,058	-370,491
	Quadra Festiva 1	-746,138	113,518	-,138	-6,573	,000	-968,855	-523,420
	Quadra Festiva 2	-276,279	98,296	-,072	-2,811	,005	-469,131	-83,427

a. Dependent Variable: Total diário de Vendas

Fonte: Elaboração própria (*output* do SPSS)

Tabela IX – *Output* do modelo 2 – Com: tendência, sazonalidade e temperatura como regressores

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,886 ^a	,784	,782	125,246

a. Predictors: (Constant), trend, Seg (Não Fer), Quadra Festiva 2, Quadra Festiva 1, Semanas tipo B, Semanas tipo G, Semanas tipo F, Semanas tipo A, Sáb (Não Fer), Semanas tipo C, Temp, Semanas tipo D, Ter-Sex (Não Fer), Semanas tipo E

b. Dependent Variable: Total diário de Vendas

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	67946790,92	14	4853342,209	309,393	,000 ^b
	Residual	18667096,03	1190	15686,635		
	Total	86613886,95	1204			

a. Dependent Variable: Total diário de Vendas

b. Predictors: (Constant), trend, Seg (Não Fer), Quadra Festiva 2, Quadra Festiva 1, Semanas tipo B, Semanas tipo G, Semanas tipo F, Semanas tipo A, Sáb (Não Fer), Semanas tipo C, Temp, Semanas tipo D, Ter-Sex (Não Fer), Semanas tipo E

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
		B	Std. Error	Beta			Lower Bound	Upper Bound
1	(Constant)	2112,454	73,799		28,624	,000	1967,664	2257,244
	Temp	-4,219	,861	-,072	-4,897	,000	-5,909	-2,529
	Seg (Não Fer)	-441,531	13,035	-,568	-33,872	,000	-467,105	-415,956
	Ter-Sex (Não Fer)	-323,996	9,956	-,601	-32,541	,000	-343,530	-304,461
	Sáb (Não Fer)	-127,553	13,030	-,164	-9,790	,000	-153,116	-101,989
	Semanas tipo A	-1218,217	74,103	-1,105	-16,440	,000	-1363,604	-1072,830
	Semanas tipo B	-1177,727	74,037	-1,061	-15,907	,000	-1322,985	-1032,469
	Semanas tipo C	-1051,219	73,861	-1,031	-14,232	,000	-1196,131	-906,306
	Semanas tipo D	-939,851	72,785	-1,559	-12,913	,000	-1082,652	-797,051
	Semanas tipo E	-838,587	72,667	-1,524	-11,540	,000	-981,156	-696,017
	Semanas tipo F	-788,674	73,540	-,789	-10,724	,000	-932,956	-644,393
	Semanas tipo G	-532,942	74,098	-,442	-7,192	,000	-678,320	-387,563
	Quadra Festiva 1	-750,031	102,333	-,139	-7,329	,000	-950,804	-549,257
	Quadra Festiva 2	-279,873	88,608	-,073	-3,159	,002	-453,718	-106,027
	trend	,165	,010	,228	16,715	,000	,146	,184

a. Dependent Variable: Total diário de Vendas

Fonte: Elaboração própria (*output* do SPSS)

Tabela X – *Output* do modelo 3 – Com: tendência, sazonalidade, temperatura e a variável artificial *Chuva no verão* como regressores; AR(9)

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,932 ^a	,869	,866	98,286

a. Predictors: (Constant), Vendas (t-9), Ter-Sex (Não Fer), Quadra Festiva 1, Semanas tipo D, Quadra Festiva 2, Chuva no verão, Semanas tipo F, Semanas tipo B, trend, Semanas tipo G, Semanas tipo C, Temp, Sáb (Não Fer), Semanas tipo A, Seg (Não Fer), Vendas (t-4), Vendas (t-3), Vendas (t-5), Vendas (t-2), Vendas (t-8), Vendas (t-7), Vendas (t-1), Vendas (t-6), Semanas tipo E

b. Dependent Variable: Total diário de Vendas

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	75040443,06	24	3126685,128	323,672	,000 ^b
	Residual	11311916,20	1171	9660,048		
	Total	86352359,26	1195			

a. Dependent Variable: Total diário de Vendas

b. Predictors: (Constant), Vendas (t-9), Ter-Sex (Não Fer), Quadra Festiva 1, Semanas tipo D, Quadra Festiva 2, Chuva no verão, Semanas tipo F, Semanas tipo B, trend, Semanas tipo G, Semanas tipo C, Temp, Sáb (Não Fer), Semanas tipo A, Seg (Não Fer), Vendas (t-4), Vendas (t-3), Vendas (t-5), Vendas (t-2), Vendas (t-8), Vendas (t-7), Vendas (t-1), Vendas (t-6), Semanas tipo E

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
		B	Std. Error	Beta			Lower Bound	Upper Bound
1	(Constant)	1672,597	69,575		24,040	,000	1536,091	1809,104
	Temp	-1,967	,710	-,033	-2,769	,006	-3,360	-,573
	Chuva no verão	87,501	26,444	,036	3,309	,001	35,617	139,384
	Seg (Não Fer)	-521,760	15,370	-,670	-33,946	,000	-551,917	-491,603
	Ter-Sex (Não Fer)	-305,986	10,933	-,566	-27,986	,000	-327,437	-284,535
	Sáb (Não Fer)	-115,236	14,952	-,148	-7,707	,000	-144,573	-85,900
	Semanas tipo A	-1078,424	61,139	-,979	-17,639	,000	-1198,378	-958,470
	Semanas tipo B	-1038,143	60,323	-,937	-17,210	,000	-1156,497	-919,789
	Semanas tipo C	-1008,315	59,888	-,985	-16,837	,000	-1125,814	-890,816
	Semanas tipo D	-928,654	58,350	-1,537	-15,915	,000	-1043,136	-814,172
	Semanas tipo E	-868,206	57,837	-1,573	-15,011	,000	-981,682	-754,730
	Semanas tipo F	-834,475	58,374	-,836	-14,295	,000	-949,005	-719,945
	Semanas tipo G	-734,948	58,831	-,611	-12,493	,000	-850,374	-619,523
	Quadra Festiva 1	-794,064	80,878	-,148	-9,818	,000	-952,747	-635,381
	Quadra Festiva 2	-223,466	70,331	-,059	-3,177	,002	-361,455	-85,478
	trend	,087	,010	,119	9,115	,000	,068	,106
	Vendas (t-1)	,318	,021	,320	15,225	,000	,277	,359
	Vendas (t-2)	,209	,018	,210	11,828	,000	,174	,243
	Vendas (t-3)	,085	,016	,085	5,262	,000	,053	,117
	Vendas (t-4)	,049	,016	,049	3,145	,002	,018	,079
	Vendas (t-5)	-,035	,020	-,035	-1,754	,080	-,073	,004
	Vendas (t-6)	,059	,022	,059	2,715	,007	,016	,102
	Vendas (t-7)	-,052	,021	-,052	-2,493	,013	-,093	-,011
	Vendas (t-8)	-,076	,020	-,076	-3,810	,000	-,115	-,037
	Vendas (t-9)	-,098	,018	-,098	-5,485	,000	-,133	-,063

a. Dependent Variable: Total diário de Vendas

Tabela XI – Coeficientes do modelo 3 – Com: tendência, sazonalidade, temperatura e a variável artificial *Chuva no verão* como regressores; AR(9)

		Total diário de Vendas	Temp	Chuva no verão	Seg (Não Fer)	Ter-Sex (Não Fer)	Sáb (Não Fer)
Pearson Correlation	Total diário de Vendas	1,000	-,329	-,091	-,271	-,286	,199
	Temp	-,329	1,000	,101	-,004	,032	-,015
	Chuva no verão	-,091	,101	1,000	-,002	,011	-,023
	Seg (Não Fer)	-,271	-,004	-,002	1,000	-,443	-,160
	Ter-Sex (Não Fer)	-,286	,032	,011	-,443	1,000	-,443
	Sáb (Não Fer)	,199	-,015	-,023	-,160	-,443	1,000
	Semanas tipo A	-,347	,216	,186	-,005	,008	,015
	Semanas tipo B	-,255	,154	,033	,007	-,023	-,013
	Semanas tipo C	-,208	,208	,140	-,003	,032	-,021
	Semanas tipo D	-,074	-,007	-,069	,012	-,012	-,005
	Semanas tipo E	,197	-,126	-,089	-,014	,002	,016
	Semanas tipo F	,139	-,141	-,033	,000	,008	,000
	Semanas tipo G	,352	-,158	-,027	,003	-,005	-,018
	Quadra Festiva 1	,033	-,027	-,006	-,020	,012	,028
	Quadra Festiva 2	,173	-,055	-,008	,006	-,007	,006
	trend	,298	-,086	-,045	-,002	-,017	,002
	Vendas (t-1)	,574	-,334	-,132	,392	-,343	-,089
	Vendas (t-2)	,466	-,314	-,114	,202	-,030	-,075
	Vendas (t-3)	,490	-,301	-,118	-,089	,167	-,085
	Vendas (t-4)	,458	-,312	-,141	-,071	,151	-,074
	Vendas (t-5)	,381	-,320	-,137	-,080	,294	-,265
	Vendas (t-6)	,488	-,326	-,151	-,072	-,032	,381
	Vendas (t-7)	,673	-,346	-,144	-,229	-,221	,182
	Vendas (t-8)	,382	-,346	-,148	,389	-,304	-,095
	Vendas (t-9)	,277	-,338	-,120	,188	,012	-,075

		Correlations								
		Semanas tipo A	Semanas tipo B	Semanas tipo C	Semanas tipo D	Semanas tipo E	Semanas tipo F	Semanas tipo G	Quadra Festiva 1	Quadra Festiva 2
Pearson Correlation	Total diário de Vendas	-,347	-,255	-,208	-,074	,197	,139	,352	,033	,173
	Temp	,216	,154	,208	-,007	-,126	-,141	-,158	-,027	-,055
	Chuva no verão	,186	,033	,140	-,069	-,089	-,033	-,027	-,006	-,008
	Seg (Não Fer)	-,005	,007	-,003	,012	-,014	,000	,003	-,020	,006
	Ter-Sex (Não Fer)	,008	-,023	,032	-,012	,002	,008	-,005	,012	-,007
	Sáb (Não Fer)	,015	-,013	-,021	-,005	,016	,000	-,018	,028	,006
	Semanas tipo A	1,000	-,067	-,074	-,159	-,207	-,076	-,061	-,013	-,018
	Semanas tipo B	-,067	1,000	-,073	-,158	-,205	-,076	-,061	-,013	-,018
	Semanas tipo C	-,074	-,073	1,000	-,173	-,225	-,083	-,067	-,014	-,020
	Semanas tipo D	-,159	-,158	-,173	1,000	-,485	-,178	-,144	-,031	-,043
	Semanas tipo E	-,207	-,205	-,225	-,485	1,000	-,232	-,187	-,040	-,056
	Semanas tipo F	-,076	-,076	-,083	-,178	-,232	1,000	-,069	-,015	-,021
	Semanas tipo G	-,061	-,061	-,067	-,144	-,187	-,069	1,000	-,012	-,017
	Quadra Festiva 1	-,013	-,013	-,014	-,031	-,040	-,015	-,012	1,000	-,004
	Quadra Festiva 2	-,018	-,018	-,020	-,043	-,056	-,021	-,017	-,004	1,000
	trend	-,097	,038	-,084	,047	-,020	,041	,052	,012	,018
	Vendas (t-1)	-,352	-,256	-,198	-,028	,182	,131	,380	,018	,008
	Vendas (t-2)	-,351	-,264	-,108	-,074	,185	,130	,376	,005	-,010
	Vendas (t-3)	-,337	-,252	-,181	-,049	,193	,133	,357	,082	-,028
	Vendas (t-4)	-,331	-,225	-,203	-,094	,231	,136	,333	,108	,022
Vendas (t-5)	-,332	-,221	-,210	-,100	,218	,127	,379	,066	,032	
Vendas (t-6)	-,331	-,209	-,230	-,103	,209	,151	,327	,098	,164	
Vendas (t-7)	-,334	-,183	-,233	-,075	,203	,142	,307	,089	,100	
Vendas (t-8)	-,339	-,166	-,178	-,085	,185	,143	,287	,070	,086	
Vendas (t-9)	-,342	-,158	-,199	-,054	,182	,144	,266	,053	,062	

Fonte: Elaboração própria (*output* do SPSS)

Apesar de os coeficientes auto-regressivos serem estatisticamente significativos destaca-se reduzido valor absolutos dos mesmos a partir de AR(3) e a elevada correlação com a os regressores sazonais.

Tabela XII – Modelo 4 – Com: tendência, sazonalidade, temperatura e a variável artificial *Chuva no verão* como regressores; AR(2)

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,924 ^a	,853	,851	103,537

a. Predictors: (Constant), Vendas (t-2), Quadra Festiva 1, Quadra Festiva 2, Ter-Sex (Não Fer), Semanas tipo D, Chuva no verão, Semanas tipo F, Semanas tipo C, trend, Temp, Semanas tipo B, Semanas tipo G, Sáb (Não Fer), Semanas tipo A, Seg (Não Fer), Vendas (t-1), Semanas tipo E

b. Dependent Variable: Total diário de Vendas

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	73802178,93	17	4341304,643	404,976	,000 ^b
	Residual	12703090,24	1185	10719,907		
	Total	86505269,16	1202			

a. Dependent Variable: Total diário de Vendas

b. Predictors: (Constant), Vendas (t-2), Quadra Festiva 1, Quadra Festiva 2, Ter-Sex (Não Fer), Semanas tipo D, Chuva no verão, Semanas tipo F, Semanas tipo C, trend, Temp, Semanas tipo B, Semanas tipo G, Sáb (Não Fer), Semanas tipo A, Seg (Não Fer), Vendas (t-1), Semanas tipo E

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
		B	Std. Error	Beta			Lower Bound	Upper Bound
1	(Constant)	1498,383	66,464		22,544	,000	1367,982	1628,784
	Temp	-1,010	,726	-,017	-1,392	,164	-2,434	,414
	Chuva no verão	94,851	27,796	,039	3,412	,001	40,315	149,387
	Seg (Não Fer)	-533,623	11,528	-,686	-46,287	,000	-556,242	-511,005
	Ter-Sex (Não Fer)	-268,781	9,020	-,499	-29,799	,000	-286,478	-251,085
	Sáb (Não Fer)	-71,828	11,234	-,092	-6,394	,000	-93,869	-49,787
	Semanas tipo A	-987,930	62,154	-,896	-15,895	,000	-1109,875	-865,986
	Semanas tipo B	-964,120	61,910	-,869	-15,573	,000	-1085,585	-842,654
	Semanas tipo C	-926,699	61,375	-,905	-15,099	,000	-1047,115	-806,284
	Semanas tipo D	-854,006	60,285	-1,416	-14,166	,000	-972,284	-735,728
	Semanas tipo E	-799,251	60,097	-1,453	-13,299	,000	-917,159	-681,343
	Semanas tipo F	-769,778	60,800	-,770	-12,661	,000	-889,064	-650,491
	Semanas tipo G	-671,879	61,553	-,558	-10,915	,000	-792,644	-551,115
	Quadra Festiva 1	-731,462	84,607	-,136	-8,645	,000	-897,459	-565,465
	Quadra Festiva 2	-187,526	73,359	-,049	-2,556	,011	-331,454	-43,598
	trend	,073	,009	,101	8,017	,000	,055	,091
	Vendas (t-1)	,349	,020	,350	17,874	,000	,310	,387
	Vendas (t-2)	,184	,016	,185	11,755	,000	,153	,214

a. Dependent Variable: Total diário de Vendas

Tabela XIII – Modelo 4 – Com: tendência, sazonalidade e a variável artificial *Chuva no verão* como regressores; AR(2)

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,925 ^a	,856	,854	102,554

a. Predictors: (Constant), Vendas (t-2), Quadra Festiva 1, Quadra Festiva 2, Ter-Sex (Não Fer), Semanas tipo D, Chuva no verão, Semanas tipo F, trend, Semanas tipo C, Semanas tipo B, Semanas tipo G, Sáb (Não Fer), Semanas tipo A, Seg (Não Fer), Vendas (t-1), Semanas tipo E

b. Dependent Variable: Total diário de Vendas

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	78245132,39	16	4890320,774	464,978	,000 ^b
	Residual	13157176,56	1251	10517,327		
	Total	91402308,94	1267			

a. Dependent Variable: Total diário de Vendas

b. Predictors: (Constant), Vendas (t-2), Quadra Festiva 1, Quadra Festiva 2, Ter-Sex (Não Fer), Semanas tipo D, Chuva no verão, Semanas tipo F, trend, Semanas tipo C, Semanas tipo B, Semanas tipo G, Sáb (Não Fer), Semanas tipo A, Seg (Não Fer), Vendas (t-1), Semanas tipo E

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
		B	Std. Error	Beta			Lower Bound	Upper Bound
1	(Constant)	1473,904	64,648		22,799	,000	1347,073	1600,735
	Chuva no verão	105,446	25,799	,045	4,087	,000	54,831	156,060
	Seg (Não Fer)	-535,068	11,057	-,691	-48,393	,000	-556,759	-513,376
	Ter-Sex (Não Fer)	-266,715	8,726	-,494	-30,564	,000	-283,835	-249,595
	Sáb (Não Fer)	-70,558	10,827	-,091	-6,517	,000	-91,800	-49,316
	Semanas tipo A	-990,029	61,275	-,947	-16,157	,000	-1110,241	-869,816
	Semanas tipo B	-961,969	61,198	-,856	-15,719	,000	-1082,030	-841,907
	Semanas tipo C	-933,462	60,469	-,991	-15,437	,000	-1052,094	-814,830
	Semanas tipo D	-854,440	59,670	-1,398	-14,320	,000	-971,504	-737,377
	Semanas tipo E	-799,814	59,485	-1,449	-13,446	,000	-916,516	-683,112
	Semanas tipo F	-770,696	60,212	-,752	-12,800	,000	-888,823	-652,569
	Semanas tipo G	-675,831	60,931	-,547	-11,092	,000	-795,369	-556,293
	Quadra Festiva 1	-732,247	83,797	-,133	-8,738	,000	-896,646	-567,848
	Quadra Festiva 2	-185,570	72,654	-,047	-2,554	,011	-328,106	-43,034
	trend	,071	,009	,097	8,144	,000	,054	,089
	Vendas (t-1)	,359	,019	,361	19,049	,000	,322	,396
	Vendas (t-2)	,186	,015	,187	12,357	,000	,156	,215

a. Dependent Variable: Total diário de Vendas

Fonte: Elaboração própria (output do SPSS)

Figura 8 – Vendas Reais vs. Valor Esperado com Indício de Heterocedasticidade




Tabela XIV – Teste de White Special

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,310 ^a	,096	,095	34931,68074

a. Predictors: (Constant), Y² ajustado, Y ajustado

b. Dependent Variable: Res²

$$Q_{\text{obs}} = n.R^2 = 122 \quad p\text{-value} = 0,000$$

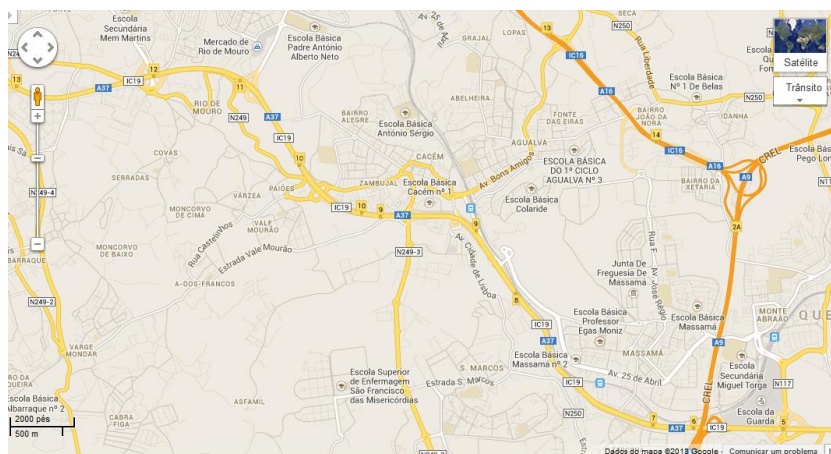
Tabela XV – Modelo com erros heterocedástico-consistentes de White

Parameter Estimates ^a				
Parameter	Estimate	Std. Error	95% Confidence Interval	
			Lower	Upper
(Intercept)	1473,904	77,774	1321,325	1626,484
Chuva_verão	105,446	24,266	57,839	153,052
Seg_dummy	-535,068	13,306	-561,171	-508,964
Ter_a_Sex_dummy	-266,715	11,911	-290,083	-243,347
Sab_dummy	-70,558	13,469	-96,982	-44,133
Sem_A	-990,029	65,156	-1117,855	-862,202
Sem_B	-961,969	65,106	-1089,697	-834,241
Sem_C	-933,462	63,220	-1057,490	-809,434
Sem_D	-854,440	62,294	-976,651	-732,230
Sem_E	-799,814	61,541	-920,547	-679,081
Sem_F	-770,696	62,656	-893,617	-647,776
Sem_G	-675,831	64,447	-802,266	-549,396
Sem_H	-732,247	71,492	-872,502	-591,991
Sem_I	-185,570	243,148	-662,587	291,447
Vendas_t_ant	,359	,037	,287	,431
Venda_t_2ant	,186	,015	,156	,216
t	,071	,009	,053	,090

a. Model: Total diário de Vendas = (Intercept) + Chuva_verão + Seg_dummy + Ter_a_Sex_dummy + Sab_dummy + Sem_A + Sem_B + Sem_C + Sem_D + Sem_E + Sem_F + Sem_G + Sem_H + Sem_I + Vendas_t_ant + Venda_t_2ant + t

ANEXO E. (6 – TRANSPORTE)

Figura 9 – Mapa de Contexto Geográfico da empresa Trigo da Aldeia



Fonte: Google maps